

T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
BİLİMSEL ARAŞTIRMA PROJELERİ KOMİSYONU BAŞKANLIĞI

Elektrik - Elektronik Müh.

201215037

FİZYOLOJİK SİNYALLER KULLANILARAK SÜRÜCÜLERİN SAĞLIK DURUMLARININ İZLENMESİ

PROJE YÖNETİCİSİ

ADI SOYADI

BİRİMİ

Yrd.Doç. Dr.Semih ERGİN / ESOGU Elektrik Elektronik Müh.

PROJE ÇALIŞANLARI

Prof. Dr. M. Bilginer GÜLMEZOĞLU / ESOGU Elektrik Elektronik Müh.
Doç. Dr. Serkan GÜNAL / Anadolu Üniv. Bilgisayar Müh.
Yard. Doç. Dr. Efnan ŞORA GÜNAL / ESOGU Bilgisayar Müh.
Yard. Doç. Dr. Alper Kürşat UYSAL / Anadolu Üniv. Bilgisayar Müh.
Prof. Dr. Alparslan BİRDANE / ESOGU Kardiyoloji

Başlama Tarihi : 24.12.2012

Proje Desteği : 94.658,00 TL

Bitiş Tarihi : 15.12.2014

İÇİNDEKİLER

Sayfa

ÖZET	3
1. GİRİŞ ve AMAÇ	5
2. YAPILAN ÇALIŞMALAR	11
2.1. Araç Simülatörünün Kurulumu	11
2.2. Mevcut Veri Tabanlarının Analiz Edilmesi.....	12
2.3. Fizyolojik Sinyal Veri Tabanı Oluşturulması.....	14
2.4. Öznitelik Çıkartım Yöntemlerinin Uygulanması	15
2.4.1 QRS Öznitelikleri.....	15
2.4.2 TD Öznitelikleri	16
2.4.3 WT Öznitelikleri	17
2.4.4 PSD Öznitelikleri.....	18
2.5. Öznitelik Seçim Yöntemlerinin Uygulanması.....	19
2.6. Sınıflandırma Yöntemlerinin Uygulanması.....	20
2.6.1 Karar Ağaçları	20
2.6.2 Yapay Sinir Ağları	21
2.6.3 Bayes	22
2.7. Benzetim Ortamında Başarım Analizi ve Eniyileme	22
2.8. Biyometrik Tanıma	23
2.9. Gerçek-Zamanlı Sistemin Tasarımı ve Gerçekleşmesi.....	26
2.10. Gerçek-Zamanlı Sistemin Eniyilenmesi	29
3. SONUÇLAR	30
3.1. Fizyolojik sinyaller kullanılarak sağlık durumlarının sınıflandırılması.....	30
3.1.1 Farklı kalp sağlık durumlarının otomatik sınıflandırılması	30
3.1.2 Kardiyak aritmilerin otomatik sınıflandırılması	32
3.2. Fizyolojik sinyaller kullanılarak biyometrik tanıma	34
3.2.1 Cinsiyet Tanıma.....	34
3.2.2 Yaş Tanıma	34
3.2.3 Kimlik Tanıma	35
4. TARTIŞMA	36
5. KAYNAKLAR.....	39
6. EK-I	44
7. EK-II.....	45

ÖZET

Bu projenin ilk aşamasında, sürücülerin araç kullanımlarının benzetim ortamında modellenebilmesi amacıyla iki adet sürüş simülatörü kurulmuştur. Projenin ikinci aşamasında, araç simülatörü üzerinde fizyolojik sinyallerin ölçümü ile yeni bir veri tabanı oluşturulması işlemine başlanmıştır. Bu işlem esnasında, cinsiyet, yaş, kilo ve boy gibi faktörleri dikkate alarak mümkün olduğunca geniş bir kitle hedeflenmiş ve ölçümlerde yer alan gönüllülerin seçiminde bu hususa dikkat edilmiştir. Bu aşamada, projenin amacına yönelik veri tabanının oluşturulmasının çok zor ve zaman alıcı olduğu görülmüş olup; kalp krizi, aritmi, taşikardi, vb. sağlık sorunu olan kişilerden ve herhangi bir sağlık problemi olmayan kişilerden toplanmış hazır bir EKG sinyal veri tabanı bulunmuştur. Normal ritim, konjestif kalp yetmezliği (congestive heart failure), karıncık taşiaritmisi (ventricular tachyarrhythmia) ve atriyal fibrilasyon (atrial fibrillation) isimli 4 farklı kalp sağlık durumunu içeren fizyolojik sinyallere zaman ve frekans düzlemlerinde analizler yapılmış ve ayırt edici bilgileri taşıyan öznitelikler çıkartılmıştır. Daha sonra, farklı tipteki öznitelik kümelerinin çeşitli kombinasyonları analiz edilerek daha yüksek ayırt ediciliğe sahip hibrid öznitelik kümesi veya kümeleri elde edilmeye çalışılmıştır. Projenin bu aşamasında, benzetim ortamında farklı öznitelik kümeleri ve sınıflandırma algoritmaları kullanılarak başarımların analizi yapılmıştır. Bu analizin sonucunda sağlık durumu sınıflandırma konusunda en yüksek ayırt edicilik sağlayan öznitelik kümeleri ve en yüksek başarımları sağlayan sınıflandırma algoritmaları belirlenmiştir.

Projenin üçüncü aşamasında, bir biyometrik kimlik belirleme çalışması yapılmıştır. Biyometrik kimlik belirleme problemi, cinsiyet, yaş ve kimlik belirlemeyi içeren 3 temel tanıma problemi olarak ele alınmıştır. Bu çalışmada göz önüne alınan her bir tanıma problemi için en yüksek F-skoru, bütün öznitelik kümeleri beraber kullanıldığında elde edilmiştir. Projenin dördüncü aşamasında ise, oldukça sık karşılaşılan kardiyak bir rahatsızlık türü olan aritmi sınıflandırma üzerine çalışmalar yapılmıştır. MIT-BIH aritmi veritabanı içerisindeki 15 farklı kalp atış tipi, ANSI/AAMI EC57:1998 standardı dikkate alınarak beş ana sınıf altında gruplandırılmış ve bu gruplar vasıtasıyla kardiyak aritmilerin otomatik sınıflandırılmasına çalışılmıştır. EKG sinyalleri üzerinden elde edilen öznitelik kümelerinin çeşitliliği göz önüne alındığında, yaygın olarak kullanılan özniteliklerin ve onların kombinasyonlarının aritmi sınıflandırma performansına katkıları, bu çalışmada kapsamlı bir şekilde irdelenmiştir. Deneyler, özniteliklerin ayrı ayrı kullanılması yerine kombinasyonlarının kullanılmasının her

iki sınıflandırıcı için daha iyi F-skorları verdiğini göstermiştir. Ayrıca bütün deneyler, ağırlıklı ortalama F-skorlarına göre Rastgele Orman (Random Forest) ağaç sınıflandırıcısının, C4.5 sınıflandırıcıdan biraz daha üstün olduğunu belirgin bir şekilde göstermektedir.

Projenin son aşamasında ise, tüm proje bulgularından yola çıkılarak gerçek-zamanlı bir sistem tasarımı ve gerçekleştirilmesi planlanmıştır. Veri toplama kartı tarafından bilgisayara iletilen sayısal EKG sinyalleri, proje kapsamında geliştirilmiş olan gerçek-zamanlı EKG sinyal işleme yazılımı sayesinde işlenmekte ve sürücü kalp sağlık durumu hakkında bilgilendirmektedir. Yazılım, öncelikle ham halde alınan sayısal EKG sinyalleri üzerinde çeşitli sayısal filtreleme ve güçlendirme işlemleri uygulamaktadır. Sonraki aşamada ise R noktalarını tespit ederek kalp ritmini ölçmekte ve dakikadaki atım sayısını değerlendirerek “normal”, “bradikardi” veya “taşikardi” şeklinde sınıflandırma yapmaktadır. Bu sayede kullanıcının temel kardiyak probleminin olup olmadığı gözlenebilmektedir. Projenin bu aşamasında, gerçek-zamanlı sistemin ürettiği sonuçların daha doğru hale getirilmesi için yazılım çeşitli testlere tabi tutularak tespit edilen hatalar giderilmiş, sinyal güçlendirme ve süzgeçleme işlemlerinin parametreleri optimize edilmiştir.

1. GİRİŞ ve AMAÇ

Günümüzde teknolojik gelişmelerin geldiği son nokta itibari ile makinelerin, cihazların insanlarla etkileşimli bir şekilde çalışması olağan hale gelmiştir. Bu alanda, insanlar arasında gerek duyularına gerekse de zihinsel fonksiyonlarına benzer etkileşimde çalışan makinelerin ve sistemlerin geliştirilmesi yıllardır ve halen de üzerinde uğraşılan bir konudur.

İnsan vücudunda temel olarak, dışarıdan çıplak gözle algılanabilen fiziksel hareketlerin yanı sıra bedenlerinde de fizyolojik olarak gerçekleşen birçok biyolojik olaylar bulunmaktadır. İlk bakışta bu konular doğrudan tıp bilimi ile ilgili gibi görünse de, insan vücudunun ve bu canlı sistemin içerisindeki ölçülebilen sinyallerin ve oluşumların matematiksel olarak modellenmesi birçok bilim dalına ait çalışma alanları ile örtüşmektedir.

Bu çalışma alanlarının en çok bilinenleri, biyomedikal bilim dalının çalışma alanlarından olan fizyolojik sinyallerdir. Son dönemdeki teknolojik gelişmelere paralel olarak, fizyolojik sinyallerin biyomedikal araştırma geliştirme kapsamında kullanıldığı bir diğer alan ise otomotiv sektörüdür. Günümüzde, taşıtlar oldukça üst seviye donanımlı bir şekilde kullanıcılara sunulabilmektedir. Araçtaki sürüş konforu, araç emniyeti gibi ek özelliklerin yanı sıra, sürücünün sağlık durumunun izlenebilmesi, hem sürücünün kendi sağlığı açısından hem de aynı araçta veya trafikteki diğer insanların emniyeti açısından acil durumlarda önem arz etmektedir.

Sürücülerin kendi rahatsızlıklarını göz ardı ederek uzun süreli yolculuklara çıkması, yolculuk başlangıcında sürücülere engel çıkarmamasına karşın, yolculuğun ilerleyen saatlerinde sürücülerin sürüşlerini ve trafiği etkileyecek biçimde olumsuzluklara sebep olmaktadır. Bu olumsuzluklar, kalp krizi, aritmi, taşikardi gibi kalbe bağlı sağlık sorunlarından kaynaklanabilmektedir. Uzun süreli sürüşün neden olduğu bu olumsuzluklar, sürücünün refleksini ve performansını önemli ölçüde zayıflatmakta, maddi ve hatta ölüme yol açan kazalara da sebebiyet verebilmektedir. İşte bu nedenle araç sürücülerinin konforlarının yanı sıra güvenliklerini arttırmaya yönelik gelişmeler gün geçtikçe yaygınlaşmakta olup, artan talebe bağlı olarak, bu donanımlara sahip araçların pazar payı da sürekli yükselme eğilimi göstermektedir. Bu nedenle, sürücülerin bazı kalp rahatsızlıkları ile ilgili sağlık durumlarını gerçek zamanlı olarak gösteren bir sistem yardımıyla kazaların önlenmesine şiddetle ihtiyaç

duyulmaktadır. Bu tür sistemler, özellikle araçlar için yol güvenliği ile ilgili kaçınılmaz bir özellik haline gelmektedir. Ülkemizde de son zamanlarda, akıllı ulaşım ve akıllı araçlar konusunda eğilim ve teşvik çalışmaları başlamış olup, önümüzdeki yıllarda da bu alanlarda büyük ilerleme kaydedilmesi planlanmaktadır.

Bu projede, fizyolojik sinyaller kullanılarak, otomobil sürücülerinin kalp rahatsızlıklarına bağlı sağlık durumlarının sürekli olarak izlenerek, normal dışı durumlarda sürücünün uyarılması hedeflenmiştir. Ayrıca bu durum, sürüş güvenliği açısından otomobillere olumlu bir özellik kazandıracaktır. Böylece, daha güvenli sürüş ortamı sağlanarak, sürücü dostu bir sistemle, hem sürücülerin sağlığının korunması, hem de kazaların sayısı azaltılarak maddi kayıpların önlenmesi amaçlanmıştır. Bu amaç doğrultusunda, projede sürücülerden gerçek zamanlı alınan sinyaller işlenerek normal dışı sağlık durumlarının teşhisi hedeflenmiştir.

Projede, normal dışı sağlık durumlarından aritmi çeşitleri ve taşikardi gibi rahatsızlıklar üzerinde çalışmalar yürütülmüştür. Projenin başlangıç aşamasında, hedeflenen çalışmalarla ilgili literatürdeki gerçekleştirilen bilimsel ve uygulamaya yönelik makaleler incelendiğinde, gerek araç içi gerekse de araç dışı uygulamalarda kişilerin kalp krizi, aritmi [1, 2, 3, 4], taşikardi [2, 3] durumlarını tespit etmek için çeşitli çalışmalar yapıldığı görülmektedir. Bu çalışmaların çoğu benzetim düzeyinde yürütülmüş olup, çok az kısmı da gerçek-zamanlı uygulama haline dönüştürülmüştür.

Bu çalışmalarda, en çok kullanılan fizyolojik sinyallerden birisi EKG sinyalıdır [1, 5, 6, 7, 8, 9, 10]. EKG, kalbin elektriksel aktivitesinin yorumlanmasıdır. İnsan vücudu üzerine takılan bir takım elektrotlar yardımıyla algılanarak, özel bir cihazla kaydedilir [11]. EKG, kalp atış hızı, kalp atış ritmi ve kalpteki anormalliklerin teşhisinde kullanılabilir. EKG sinyallerinin doğru bir şekilde yorumlanması, kalp rahatsızlıklarının değerlendirilmesi açısından hayati bir önem taşımasından dolayı, değişik kalp problemlerine ait EKG sinyallerinin analizi ve sınıflandırılması ile ilgili birçok çalışmalar yapılmıştır [1, 2, 12, 13, 14, 15, 16, 17].

Proje kapsamında da ele alınan kalple ilgili düzensizlik anlamına gelen aritmi, anormal kardiyak elektriksel aktivitelerin gözleendiği bir grup koşul için kullanılan genel bir isimdir [18]. Kardiyak aritmileri, hipertansiyon ve koroner atardamar hastalıkları gibi

kardiyovasküler hastalıklar [19] olarak kişilerde sıklıkla görülür [20]. Ventriküler fibrilasyon gibi aritmilerin birçok tipi, kalp krizine ve ani ölümlere neden olabilecek yaşamı tehdit eden anormalliklerdir. Diğer bir aritmi tipi olan atriyal fibrilasyon, yaşamın kalitesini etkileyen embolik komplikasyonlara neden olabilir [21]. Sonuç olarak aritmilerin erken teşhisi, uygun tedaviler ile hastanın yaşam kalitesini artırabilir ve ömrünü uzatabilir [22]. Elektrokardiyogram (EKG) genellikle, aritmilerin farklı tiplerini ayırt etmek için son derece etkili tanısal araç olarak tercih edilir [20]. EKG sinyallerinden ayırt edici özniteliklerin türetilmesi, ani kardiyak ölümlerinin risk değerlendirmesini yapmak için kullanılabilir [23].

Benzer amaçlar için kullanılan diğer fizyolojik sinyaller BCG [24, 25, 26] ve PPG [4, 27, 28, 29, 30] sinyalleridir. Bu tip fizyolojik sinyallerin araç-içi uygulamalarda doğru ölçülebilmesi için çeşitli çalışmalar bulunmaktadır [27, 28, 29, 30, 31, 32, 37].

Literatürdeki mevcut çalışmalarda, fizyolojik ve psikolojik durumları belirlemede EKG sinyallerinden gereksiz veri kaldırılırken, ayırt edici bilgiyi ortaya çıkaran öznitelik çıkartım teknikleri kullanılmıştır. Öznitelik türetmenin rolü, EKG sinyal analizi için çok önemlidir. Aritmi tarzı rahatsızlıkların yanı sıra, diğer kalp anormalliklerini yakalamak için de EKG sinyallerinin sınıflandırılmasında kullanılan çeşitli öznitelik türetme stratejilerinin bulunduğu çok sayıda çalışma literatürde mevcuttur.

Öznitelik çıkartımı için, genellikle, Temel Bileşen Analizi [1], Kesikli Dalgacık Dönüşümü [2, 12, 13, 14], Fraktal boyut tabanlı öznitelikler [15, 16, 33, 34, 35, 36], Bulanık (Fuzzy) karşılıklı bilgi Dalgacık paketi [5, 17], standart kardiyoloji ve zaman düzlemi öznitelikleri [12], morfolojik öznitelikler [14, 38], morfolojik dalgacık dönüşümü [39], zaman düzlemi [12, 39], zamanlama bilgisi ile birlikte çok ölçekli dalgacık dönüşümleri [40], güç spektral yoğunluğu [17, 41], QRS aralığı [42], RR aralık dizisi [43], EKG sinyallerinin R tepe noktaları [44], kalp atış aralığı öznitelikleri [38] vb. öznitelik çıkartım yaklaşımları kullanılmaktadır.

Elde edilen öznitelikleri kullanarak sınıflandırma amacıyla ise, Yapay Sinir Ağları [2, 3, 6, 12, 45], Doğrusal / Doğrusal Olmayan Ayırtaç Analizi [10, 12, 13], Destekçi Vektör Makinesi [3, 7, 9, 14], Mahalanobis Temelli En Küçük Uzaklık [13], Parçacık Küme Eniyilemesi [14] vb. yöntemler kullanılmaktadır.

Wang ve arkadaşları, PCA ve LDA'yı birleştiren bir öznitelik indirgeme yöntemini kullanan etkili bir aritmi sınıflandırma planı sunmuşlardır [46]. Zaman düzlemindeki öznitelikler (QRS morfolojisinin temel bileşenleri, RR aralığı ve QRS aralığı); normal, anormal bir yerde süperventriküler, anormal bir yerde ventriküler ve füzyon atışını içeren dört tip EKG atışı için sınıflandırılmıştır [42].

EKG sinyali kullanılarak, kişideki muhtemel kalp rahatsızlıklarının tespiti yapılabileceği gibi, bu proje kapsamında EKG analizinin sürücüler için yapıldığı göz önüne alınırsa, aynı sinyalden biyometrik kimlik tanıma yapılabilmesi ile ilgili literatürde çalışmaların olması projenin diğer bir kısmını oluşturmuştur. Böylece aracın çalınma vb. güvenliğinin tehlikeye girme ihtimaline karşı, araç tarafından önceden tanımsız EKG sinyaline sahip kişilerin aracı kullanmaları engellenebilecektir.

Gelişmiş teknolojiler, özel dokümanların korunması ve sınırlı alanlara güvenli giriş gibi birçok biyometrik kimlik belirleme uygulamalarına başarılı bir şekilde uygulanabilir [47]. Biyomedikal ve klinik mühendisliği alanlarındaki son gelişmeler, sadece biyometrik kimlik belirleme sistemlerinin tanıma performansını iyileştirmekle kalmayıp, aynı zamanda gerçekleştirilebilir uygulamalara olanak sağlar [48]. ID kartlar ve anahtar kodlar gibi kişi tanımlama çalışmalarında kullanılan geleneksel araçlar, onların sahipleri olmasa bile kolaylıkla değiştirilebilmelerinden dolayı genelde güvenli değildir [49]. Bununla beraber, bir biyometrik kimlik belirleme, kişinin fizyolojik karakteristiklerini göz önüne alarak kişiyi tanımlamak için etkin bir güvenlik sağlar [50].

Son yıllarda, kişilerden toplanan EKG sinyalleri, kimlik doğrulama için bir biyometrik olarak önerilmektedir [47, 51, 52]. EKG sinyallerinin doğasında, kalbin elektriksel özellikleri mevcuttur. Kalp atış hızı, nabız atışı ve yapı bilgisi hakkındaki bilgiler, insan vücuduna yerleştirilen belli sayıdaki elektrotlar vasıtasıyla kaydedilen EKG sinyallerinden elde edilebilir [53]. EKG kaydı, kişinin kalbi ile ilgili özellikleri içermesinden dolayı, biyometrik tanıma için kişiye özgü yeterli örüntüleri taşır [50, 54]. Bunların yanında EKG sinyali, bir kişinin canlılığını gösteren önemli bir araç olarak da düşünülebilir ve diğer biyometrik sinyaller ile karşılaştırıldığında taklit edilmesi oldukça zordur.

Çoğu EKG tabanlı biyometrik kimlik tanıma sistemleri, EKG sinyalinden türetilmiş farklı özniteliklerden faydalanırlar ve genellikle, denetlenen sınıflandırma yaparlar [55, 56]. EKG sinyalinde bulunan Q, R ve S noktalarını bulma işlemi, bu amaç için yaygın olarak kullanılmaktadır [50, 53, 57, 58]. Zamansal ve genlik öznitelikleri, kişi tanımlamada yaygın olarak kullanılmaktadır [48, 53, 54, 59, 60]. MFCC [61], PCA [61], ICA [62], DCT [52, 53] ve Dalgacık [62] yaklaşımları, EKG sinyallerinden ayırt edici biçimsel öznitelikler çıkartmak için de kullanılırlar. Korelasyon katsayıları (CCORR) ve dalgacık uzaklık ölçütü (WDIST) öznitelikleri, kişi tanımlama için önerilmektedir [63]. Wilk'in Lambda yöntemi [63], Fourier dönüşümü [64] ve vektör kardiyogram [49] da, öznitelik çıkartımı için ECG sinyallerine uygulanabilir. Hem güç spektrumu katsayılarını, hem de zamansal bilgiyi kullanan gürbüz bir ECG biyometrik kimlik belirleme algoritması referans [65] da önerilmiştir. Yerel bölütlerin seyrek betimlenmesine dayalı kişi tanımlama için ECG sinyallerinden yoğun ve ayırt edici öznitelikler çıkartılmaktadır [66].

Literatürde, EKG tabanlı biyometrik tanıma için çok sayıda yaklaşım önerilmiştir. Son derece yaygın olan yöntemlerden biri, uzaklık ölçütü kullanmaktır [48, 50, 56, 58, 60, 67]. Aynı zamanda en yakın komşuluk sınıflandırıcısı, bu amaç için yaygın olarak kullanılmaktadır [47, 61, 66, 68, 69, 70]. Yapay Sinir Ağları [52] ve Karar Tabanlı Sinir Ağları [59, 60] da kişi tanımlamaya etkin bir şekilde uygulanmaktadır. Destek Vektör Makinesi [49, 62, 65], Korelasyon Katsayıları ile Şablon Eşleştirme [50, 51], Radyal Temel Fonksiyon [57, 62], GMM [65], Ardışık Süreçlerin İstatistiksel Teorisi [71] ve Benzerlik veya Benzeşmezlik Ölçütü [55], son zamanlarda önerilen diğer yöntemlerdir. Coutinho ve arkadaşları, algoritma tabanlı çapraz karmaşıklığın tahmin edilmesi ile Ziv-Merhav çapraz ayırıştırma algoritması önermişlerdir [72]. Kişi tanımlama için kullanılan diğer sınıflandırıcılardan bazıları, Doğrusal Ayırtaç Analizi [53, 54], eşik değerli Dalgacık tabanlı sınıflandırıcı [51], kademeli sınıflandırıcı [63] ve kümelemedir [73]. Ayrıca, ECG biyometrik tanıma için karşılaştırmalı bir analiz, [74] da yapılmıştır.

Yukarıda bahsedilen literatür çalışmalarının incelenmesi sonucunda proje kapsamında, sürücünün sağlık durumunu inceleme amaçlı sürücüden alınan EKG sinyalleri, temel kalp hastalıkları açısından sınıflandırma çalışmaları yapılmıştır. Böylece proje kapsamında, sürücünün EKG sinyali hem kalp rahatsızlıkları açısından incelenebilmekte hem de bu sinyalin kime ait olduğu bilgisi doğrulanabilmektedir.

2. YAPILAN ÇALIŞMALAR

Proje kapsamında yapılan çalışmalar, proje önerisinde öngörülmüş olan proje aşamalarına ve zamanlarına uygun şekilde yürütülmüştür. Ayrıca, proje önerisinde yer verilmeyen, ancak projenin ilerleyen safhalarında projeye önemli bir katkı katacağı değerlendirilen biyometrik tanıma çalışması da eklenmiştir. Yapılan çalışmaların her biri ilerleyen bölümlerde detaylı şekilde açıklanmıştır.

2.1. Araç Simülatörünün Kurulumu

Bu aşamada, projenin başlatılması için gerekli makine/teçhizatın ihale usulü ile alınma işlemi tamamlanmış ve tarafımızdan teslim alınmıştır. Daha sonra, sürücü koltukları, direksiyon ve pedal sistemleri, ayaklı 3D LED TV'ler ve kişisel bilgisayarların uygun şekilde bir araya getirilmesiyle Şekil 2.1'de görülen araç simülasyon sistemi kurulmuştur. Proje çalışmalarında kullanılmak üzere bu sistemden iki adet oluşturulmuştur. Aşağıdaki şekilde görüleceği gibi, sürücü koltuğu, direksiyon sistemi, gaz ve fren pedalları, aracın iç görünümüne; kullanılan LED TV ekranı ise, sürüş anındaki görüş alanına benzetim yapmaktadır.



Şekil 2.1. Kurulan araç simülatörü

Araç simülatörünü çalışır hale getirmek için gerçek zamanlı sürüşü temsil edebilecek uygun bir yazılıma ihtiyaç duyulmuştur. Bu amaçla, proje bütçesinden temin edilen “City Car Driving” isimli yazılım bilgisayarlara kurulmuştur. Şekil 2.2’de, belirtilen yazılımın ana menüsü gösterilmektedir.



Şekil 2.2. Sürüş simülasyon yazılımının ana menüsü

Kurulan platformun çalışmasından örnek bir görüntü ise Şekil 2.3'te görülmektedir. Sürücüyeye, direksiyon, pedallar ve şekildeki ekran görünümü yardımıyla gerçek araç kullanımına oldukça yakın bir ortam sağlanmaktadır. Mevcut yazılımın yol durumlarıyla ilgili ayarları da bulunduğuundan, trafik yoğunluğu, hava şartları gibi gerçek hayatta sürüşü etkileyebilecek birtakım değişkenler yazılım ortamında ayarlanabilmektedir. Bu değişkenler, sürücünün farklı koşullardaki sürüş ortamlarında sağlık durumunun tespitine imkân sağlaması açısından önemlidir.




Şekil 2.3. Araç simülatörünün çalışması


2.2. Mevcut Veri Tabanlarının Analiz Edilmesi

Projenin bu aşamasında, aritmi, taşikardi, uyuşukluk gibi sağlık sorunu olan ve stres seviyesi yüksek olan kişilerden ve herhangi bir sağlık problemi olmayan kişilerden toplanmış hazır bir fizyolojik sinyal veri tabanı literatürde araştırılmıştır. Yürütülen bu araştırmalar sonucunda, iyi bilinen Physiobank sinyal arşivinin [75] kullanılmasına karar verilmiştir. Bu


veri tabanında, gerek sağlıklı gerek farklı kalp rahatsızlıkları bulunan kişilerden alınmış EKG sinyal örnekleri bulunmaktadır. Örnek olarak, bu veri tabanından elde edilmiş normal ritim, konjestif kalp yetmezliği (congestive heart failure), karıncık taşiaritmis (ventricular tachyarrhythmia) ve atriyal fibrilasyon (atrial fibrillation) durumlarına karşılık gelen EKG sinyalleri Şekil 2.4’te verilmektedir.




(a)



(b)



(c)




(d)


Şekil 2.4. Örnek EKG sinyalleri (a) normal ritim (b) konjestif kalp yetmezliği (c) karıncık taşiaritmis (d) atriyal fibrilasyon.

2.3. Fizyolojik Sinyal Veri Tabanı Oluşturulması


Projenin bu aşamasında, araç simülatörü üzerinde fizyolojik sinyallerin ölçümü ile yeni bir veri tabanı oluşturulması işlemine başlanmıştır. Bu işlem esnasında, cinsiyet, yaş, kilo ve boy gibi faktörleri dikkate alarak mümkün olduğunca geniş bir kitle hedeflenmiş ve ölçümlerde yer alan gönüllülerin seçiminde bu hususa dikkat edilmiştir. Simülatör üzerine yerleştirilen algılayıcılar ile elde edilen fizyolojik sinyallerden alınmış örnek kesitler Şekil 2.5.'te görülmektedir.




Cinsiyet: Erkek | Yaş: 35 | Kilo: 75 | Boy: 172



Cinsiyet: Kadın | Yaş: 35 | Kilo: 74 | Boy: 167



Cinsiyet: Erkek | Yaş: 52 | Kilo: 80 | Boy: 185



Cinsiyet: Erkek | Yaş: 33 | Kilo: 90 | Boy: 165

Şekil 2.5. Çeşitli EKG sinyal örnekleri

Veri tabanının en güncel hali dikkate alındığında, toplanan sinyallerin dağılımı, Çizelge 2.1'de listelenmiştir.

Çizelge 2.1. Veri tabanındaki sinyallerin dağılımı

Cinsiyet		Yaş			Kilo (kg)			Boy (cm)		
Erkek	Kadın	18 - 25	25 - 50	>50	50-69	70-89	>89	<169	170-179	>179
%80	%20	%50	%30	%20	%25	%55	%20	%20	%60	%20


2.4. Öznitelik Çıkartım Yöntemlerinin Uygulanması

Projenin bu aşamasında, fizyolojik sinyallerin sınıflandırılmasında kullanılan, ayırt edici bilgileri taşıyan özniteliklerin çıkartımı konusunda çalışmalar yürütülmüştür. QRS, zaman düzlemi (time domain - TD), dalgacık dönüşümü (wavelet transform - WT) ve güç spektral yoğunluğu (power spectral density PSD) tabanlı öznitelikler, EKG sinyallerinden anlamlı bilgiler çıkartmak için literatürde sıklıkla kullanılmıştır. Bu öznitelikler aşağıda detaylı olarak açıklanmıştır.

2.4.1 QRS Öznitelikleri

Genellikle bir EKG sinyali, P, Q, R, S ve T dalgalarını içeren toplam 5 adet sapmaya sahiptir. Q, R ve S dalgaları, sıra ile oluşur ve tek bir olayı gösterir. Bunlar genellikle, hep beraber QRS olarak göz önüne alınır. Q dalgası, P dalgasından sonra aşağıya doğru sapmayı gösterir. R dalgası, yukarı bir sapma olarak takip eder. S dalgası, R dalgasını takip eden aşağıya doğru bir sapmadır ve T dalgası, S dalgasını takip eder. Şekil 2.6 örnek bir EKG sinyalindeki QRS kompleksinin yapısını açıklamaktadır.

Bu çalışmada kullanılan QRS öznitelikleri; PR aralığı, R dalga süresi, P+ genliği, QRS p-p genliği, R dalga genliği, ST genliği, T+ genliği, QRS dalga alanı ve ST eğimi olarak listelenebilir. PR aralığı, P dalgasının başlangıcı ile elektrokardiyogramın QRS kompleksi arasındaki süredir. Bu süre, atriyal kutuplaşmayı kaldırmanın başlangıcı ile karıncıkla ilgili kutuplaşmayı kaldırmanın başlangıcı arasındaki sinyalleri içerir [76] R dalga süresi, R dalgasının başı ile sonu arasında geçen zamandır [77]. P+ genliği, P noktası ile sinyalin tekrar yükselmeye başladığı diğer ardışık nokta arasındaki fark olarak tanımlanabilir. QRS p-p genliği, QRS kompleksindeki R ve Q noktaları arasındaki genlik cinsinden farktır [77]. R dalga genliği, sınır çizgisinden R dalgasının yüksekliği olarak tanımlanabilir. ST genliği, S ve T noktaları arasındaki genlik değerleri cinsinden farktır [77].



Şekil 2.6. Örnek bir EKG sinyali

T+ genliği, T noktası ile sinyalin tekrar yükselmeye başladığı ardışık nokta arasındaki fark olarak tanımlanabilir [77]. QRS dalga alanı; Q, R ve S noktalarını kullanarak QRS kompleks üzerinde çizilen dikdörtgenin alanıdır [78]. ST eğimi, QRS kompleksinin S noktasından T noktasına çizilen doğrunun açısıdır.

2.4.2 TD Öznitelikleri

TD öznitelikleri, doğrudan EKG sinyalinin zaman düzlemindeki değerlerinden çıkartılabilir. Belli bir zaman aralığındaki EKG sinyalinin enerjisi, ortalaması, standard sapması, maksimumu, minimumu, ikinci momenti, üçüncü momenti ve maksimum ile minimum noktaları arasındaki fark, ayırt edici öznitelikler olarak kolaylıkla hesaplanabilir.

Enerji özniteliği, aşağıdaki gibi hesaplanabilir:

$$E_{TD} = \sum_{i=1}^N x_i^2. \quad (1)$$

Burada x_i , o anki penceredeki i 'nci örnek ve N , pencere büyüklüğüdür. Ortalama özniteliği, aşağıdaki formül vasıtasıyla elde edilir

$$m_{TD} = \frac{\sum_{i=1}^N x_i}{N}, \quad (2)$$

ve standart sapma

$$\sigma_{TD} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - m_{TD})^2}. \quad (3)$$

formülü yardımıyla hesaplanır. Maksimum ve minimum öznitelikleri, sırasıyla, aşağıdaki gibi elde edilir:

$$\max_{TD} = \max \{x_i, 1 \leq i \leq N\} \quad (4)$$

ve

$$\min_{TD} = \min \{x_i, 1 \leq i \leq N\}. \quad (5)$$

Yüksek dereceden istatistiksel öznitelikler, ikinci ve üçüncü momentler, aşağıdaki gibi elde edilir:

$$\text{skewness}_{TD} = \frac{\sum_{i=1}^N (x_i - m_{TD})^3}{(N-1)\sigma_{TD}^3} \quad (6)$$

ve

$$\text{kurtosis}_{TD} = \frac{\sum_{i=1}^N (x_i - m_{TD})^4}{(N-1)\sigma_{TD}^4} - 3. \quad (7)$$

Maksimum ve minimum noktalar arasındaki fark olarak tanımlanan son TD özniteliği

$$\text{diff}_{TD} = \max_{TD} - \min_{TD}. \quad (8)$$

vasıtasıyla elde edilir. Böylece, S boyutlu TD öznitelik vektörü, EKG sinyalinin her bir çerçevesinden türetilir.

2.4.3 WT Öznitelikleri

Frekans temelli teknikler, sınıflandırma amacı için EKG sinyallerini temsil eden yararlı bilgileri kolaylıkla çıkartabilirler [41]. Frekans tabanlı öznitelikleri elde etmenin etkili yollarından birisi, onun güçlü zaman frekans lokalizasyon özelliği ile dalgacık dönüşümüdür. Dalgacık dönüşümü ve Fourier dönüşümü, sinyali daha basit bileşenlerine ayrıştırmalarından dolayı birbirine benzerdir. Bununla beraber, WT bu amaç için sinüs eğrilerinden ziyade dalgacıkları (yani, ana bir dalgacığın ölçeklenmiş ve kaydırılmış versiyonlarını) kullanır. WT’de ilk olarak sinyal, kendisinin düşük (yani yakınlık) ve yüksek (yani detay) frekanslı bileşenlerine ayrıştırılır. Ayrıştırmanın daha sonraki seviyeleri, son yaklaşık bileşen üzerinden yürütülür [79]. Alternatif olarak, eğer dalgacık paket analizi kullanılıyorsa, tam bir alt bant ayrıştırması gerçekleştirmek için hem yakınlıklar hem de detaylar bütün seviyelerde ayrıştırılır [80]. Bu çalışmada, WT özniteliklerini türetmek için dalgacık paket analizi tercih

edilmiştir, çünkü bir EKG sinyali, kendisinin hem düşük hem de yüksek frekanslı bileşenleri içerisinde anlamlı bilgileri taşıyabilir. Özellikle 32 alt bant, her bir çerçeve üzerinde 5 seviyeli dalgacık paket ayrıştırması kullanılarak elde edilir. Daha sonra bu alt bantların enerjileri, her bir çerçevede 32 boyutlu WT öznitelikleri elde etmek için hesaplanır.

2.4.4 PSD Öznitelikleri

Diğer bir ayırt edici öznitelik çıkartma tekniği olarak, EKG sinyalinin güç spektral yoğunluğu Welch'in yöntemi kullanılarak tahmin edilebilir. Herhangi bir sinyalin PSD'sinin tahmininden sonra diğer türetilen öznitelikler, PSD bilgisinden kolaylıkla elde edilebilir. Enerjiyi, ortalamayı, standart sapmayı, maksimumu, minimumu, ikinci momenti ve üçüncü momenti içeren ilk yedi PSD öznitelikleri, (1)-(7) numaralı denklemlere benzer denklemler kullanılarak hesaplanır.

Kalan dört öznitelik, PSD verisinin yerel fraktal boyut (FD) değerleridir. İlk olarak Mandelbrot [81] tarafından ortaya atılan fraktal, uzun yıllar boyunca, kendine benzerlik özelliğini araştıran matematiksel bir tekniktir. Kendine benzerlik demek, yapının herhangi bir ölçeğinde sürekli aynı istatistiksel özelliklere sahip olmasıdır. PSD tabanlı fraktal tahmin edici, fizyolojik sinyallerin FD tahmini için iyi bilinen yöntemlerden biridir [35]. FD hesaplama aşamasında, dört farklı FD değeri, sinyalin PSD sinin eşit olarak bölünen parçalarından elde edilir. PSD'yi dörtten daha fazla parçaya bölmenin, sınıflandırma performansını belirgin bir şekilde artırmadığı fakat işlem süresini artırdığı, deneysel olarak gösterilmiştir. [82] no'lu referansta tanımlandığı gibi, kesikli bir dizinin FD'si, güç spektrumu $S(f_n)$ yi kullanarak hesaplanır. Fraktal sürecin güç spektrumu, aşağıdaki ifadede verildiği gibi güç kuralının bir ilişkisidir:

$$S(f_n) \cong p f_n^{-\beta}, \quad (9)$$

Burada f_n , frekansı ve β , spektral üssü göstermektedir. Bu ifade, her iki tarafın logaritmasını alarak doğrusallaştırılır:

$$\log S(f_n) \cong \log p - \beta \log f_n. \quad (10)$$

Buradan, f_n ' e karşı $S(f_n)$ 'nin log-log çizimi için en küçük kareler regresyonundan sonra doğrunun eğimi, β değerine eşit olacaktır. PSD eğrisinden β 'nın tahmin edilmesinden sonra yerel FD,

$$FD = \frac{5-\beta}{2} \quad (11)$$

olarak elde edilir. Sonuç olarak bu aşamada, 11 boyutlu PSD öznitelikleri ileriki süreçler için hazır hale getirilmiştir.

2.5. Öznitelik Seçim Yöntemlerinin Uygulanması

Projenin bu aşamasında, farklı tipteki öznitelik kümelerinin çeşitli kombinasyonları analiz edilerek daha yüksek ayırt ediciliğe sahip hibrid öznitelik kümesi veya kümeleri elde edilmeye çalışılmıştır. Bu amaçla, önceki bölümde detayları verilmiş olan QRS, TD, WT ve PSD temelli özniteliklerin ayrı ayrı ve çeşitli kombinasyonlarının sınıflandırma başarımı karşılaştırmalı olarak analiz edilmiştir. Ayrıca, başarılı bir saran (wrapper) öznitelik seçim yöntemi olan Ardışık İleri Yönde Kayan Seçim (SFFS: Sequential Floating Forward Selection) yöntemi de ayırt edici özniteliklerin belirlenmesinde kullanılmıştır.

Standart Ardışık ileri yönde seçim yöntemi, “aşağıdan yukarıya” doğru çalışır. Yöntem, ilk olarak [83] çalışmasında sunulmuştur. Boş bir öznitelik kümesiyle işleme başlayarak, her bir adımda o anki öznitelik altkümesinin ölçüt fonksiyonu değerini eniyileyen öznitelik, altkümeyle eklenir. Bu işlem, istenen öznitelik boyutuna ulaşınca kadar tekrarlanır. Ardışık ileri yönde seçim yönteminde, her adımda tek bir öznitelik altkümeyle eklenir. Ardışık geri yönde seçim yöntemi ise “yukarıdan aşağıya” doğru çalışır. Yöntem, ilk olarak [84] çalışmasında önerilmiştir. Burada, ardışık ileri yönde seçimin tersi bir durum söz konusudur. Başlangıçta öznitelik kümesinin tamamı göz önüne alınarak, her bir adımda o anki öznitelik altkümesinin ölçüt fonksiyonu değerini eniyeleyecek şekilde bir öznitelik kümeden çıkarılır. Çıkarma işlemi, istenen öznitelik boyutuna ulaşınca kadar tekrarlanır. Ardışık ileri ve geri yönde seçim yöntemlerinin maruz kaldığı içiçelik (nesting) etkisi, seçim esnasında belli oranda ters yöne hareket ederek kısmen giderilebilir. Bunun için, seçim işleminin bir adımında l adet öznitelik ileri yönde seçim yöntemiyle kümeyle eklendikten sonra, r adet öznitelik geri yönde seçim ile kümeden çıkarılır. Bu yöntem, “Artı l – Çıkar r ” olarak isimlendirilmiştir [85]. Burada, içiçelik etkisi belli oranda azalmasına rağmen, yöntem halen ileri ve geri yönde seçimi temel aldığı için alt eniyi sonuç verir. Ancak, en iyi öznitelik kümesini elde edebilmek için bu parametrelerin hangi değeri alması gerektiğini belirleyen teorik bir yöntem mevcut değildir. Bu yüzden, [86] çalışmasında önerilen Ardışık İleri Yönde Kayan Seçim Yöntemi, l ve r parametrelerini sabitlemek yerine kaymalarını sağlar. Böylece seçimin herhangi bir adımında, ölçüt fonksiyonu mevcut değerinden daha iyi bir değere

ulaşıncaya kadar aynı yönde hareket edilir. Bu esnek yapı, öznitelik kümesi boyutunun her adımında tekdüze olmayan bir şekilde değişmesini sağlar.

2.6. Sınıflandırma Yöntemlerinin Uygulanması

Proje kapsamında, karar ağacı, yapay sinir ağları ve Bayes temelli sınıflandırma yöntemlerinden faydalanılmıştır. Bu yöntemlerin detayları aşağıda açıklanmıştır.

2.6.1 Karar Ağaçları

Karar verme veya sınıflandırma ağaçları (DT: decision tree), kabul edilen(istenilen) sınıfa ulaşıncaya kadar sınıfların ardışık olarak reddedildiği (iptal edildiği) çok aşamalı karar verme sistemleridir [87]. Bu amaçla, öznitelik uzayı ilgili sınıf kadar tekil bölgelere bölünmektedir(parçalanmaktadır). En çok kullanılan karar ağaç tipi öznitelik değerlerini bir eşik değeri ile karşılaştırarak, öznitelik uzayını iki parçaya bölen ikili sınıflandırma ağacıdır. Böylece bilinmeyen bir öznitelik vektörü verildiğinde, karar ağacının düğüm yolları boyunca, Evet/Hayır karar dizileri aracılığıyla belirli bir sınıfa atanır. Sınıflandırma ağacı tasarlanırken (i) Bölme kriteri (ii) Bölmeyi durdurma kriteri (iii) Sınıf atama kuralına dikkat edilmelidir.

Öznitelik uzayını bölmenin en temel amacı önceki altkümelere göre daha homojen altkümeler oluşturmaktır. Entropi katkısını tanımlamak için yaygın olarak kullanılan bir bilgi olarak,

$$I(t) = - \sum_{i=1}^M P(c_i | t) \log_2 P(c_i | t) , \quad (12)$$

denklemini kullanılır. Bu denklemde, $P(c_i | t)$ c_i , $i = 1, 2, \dots, M$. sınıfından t düğümüne ait X_t altkümesi içerisindeki vektörün olasılığıdır. Bölme işlemi gerçekleştirilirken, $N_t Y$ noktaları “Evet” düğümüne ($X_t YES$), $N_t N$ noktaları ise “Hayır” düğümüne gönderilen noktalar olarak kabul edilir. Düğüm katışkılarındaki azalma şu şekilde tanımlanır;


$$\Delta I(t) = I(t) - \frac{N_{tY}}{N_t} I(t_{YES}) - \frac{N_{tN}}{N_t} I(t_{NO}) , \quad (13)$$

$I(t_{YES})$ ve $I(t_{NO})$ sırasıyla the t_{YES} and t_{NO} düğümlerinin katışkılarıdır. Eğer düğüm katışkılarındaki en yüksek azalış, belirli bir eşik değerinden az ise veya bir bölmeyi takibeden tekil bir sınıf elde ediliyorsa bölme işlemi sonlandırılır. Bir düğüm terminal veya yaprak olarak tanımlanıyorsa sınıf ataması yapılır. Genelde kullanılan atama yöntemi, bir yaprağı

ilgili alt küme içerisinde vektörlerin çoğunluğunun ait olduğu sınıfa atayan majority (çoğunluk) kuralıdır. Rastgele Orman (Random Tree) sınıflandırıcısı ise birden fazla karar ağacının birlikte kullanıldığı özel bir çeşit karar ağacı temelli sınıflandırıcıdır.

2.6.2 Yapay Sinir Ağları

Yapay sinir ağları, örüntü tanıma problemlerinin çözümünde yaygın olarak kullanılan başarılı sınıflandırıcılardandır [88]. Perseptron gibi bazı yapay sinir ağları doğrusal sınıflandırma problemleri için başarılı sonuçlar üretirken, çok katmanlı sinir ağları hem doğrusal hem de doğrusal olmayan sınıflandırma problemlerine çözüm getirebilmektedir. Bir sinir ağı, temel işlem birimleri olan ve birbirlerine ağırlıklandırılmış bağlarla bağlanmış nöronlardan oluşur. Çok katmanlı sinir ağlarında giriş (input), çıkış (output) ve gizli (hidden) katman(lar) (layer) bulunur. Çoğu problemde tel bir gizli katman yeterli iken, bazı durumlarda iki katman kullanmak başarıyı artırabilmektedir. Çok-katmanlı ileri beslemeli basit bir sinir ağı Şekil 2.7’de görülmektedir. Burada, n giriş vektörü boyutunu, m ise çıkış sayısını temsil etmektedir.



Şekil 2.7. Çok-katmanlı ileri beslemeli sinir ağı

Geri-yayılım, çok-katmanlı ileri beslemeli sinir ağlarının eğitimi için kullanılan yaygın yöntemlerden biridir. Geri-yayılım ile eğitim 3 aşamadan oluşur:

- Giriş eğitim örüntüsünün ileri beslemesi
- Hatanın geri yayılımı
- Ağırlıkların düzenlenmesi

Geri yayılım eğitiminin Levenberg-Marquardt, gradyan descent, momentum ile gradyan descent ve adaptif öğrenme oranı gibi farklı varyantları bulunmaktadır. Aşamalar, önceden belirlenmiş sonlandırma ölçütleri temel alınarak iteratif şekilde tekrar edilir.

2.6.3 Bayes

Basit Bayes (NB: Naive Bayes) sınıflandırma yönteminde, öznitelik vektörünü oluşturan özniteliklerin tamamının istatistiksel olarak bağımsız olduğu kabul edilir [87]. Bu kabullenmeden yola çıkarak, d-boyutlu x öznitelik vektörü, c_i , $i = 1, 2, \dots, M$ sınıflarından birine,

$$Sınıf = enbüyük \prod_{k=1}^d p(x_k | c_i) \cdot \quad (14)$$

kuralına göre atanır. Burada, $p(x_k | c_i)$ ifadesi, c_i sınıfı verilmişken, x öznitelik vektörü içindeki k 'nci özniteliğin olasılığını temsil eder. Dağılımın türünün normal olduğu kabullenmesi yapılarak, olasılık yoğunluk fonksiyonunun değeri şu şekilde hesaplanmaktadır:

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right). \quad (15)$$

Bu denklemde, m ve σ , x özniteliğinin sırasıyla ortalamasını ve standart sapmasını göstermektedir.

Standart Bayes sınıflandırmada ise özniteliklerin tamamının istatistiksel olarak bağımsız olduğu kabullenmesi yoktur. Bu doğrultuda, hesaplamalar vektörel olarak gerçekleştirilir. Başka bir ifadeyle, skaler öznitelikler, öznitelik vektörüne; ortalama değer, ortalama vektörüne; standart sapma ise kovaryans matrisine dönüşür.


2.7. Benzetim Ortamında Başarım Analizi ve Eniyileme

Projenin bu aşamasında, benzetim ortamında farklı öznitelik kümeleri ve sınıflandırma algoritmaları kullanılarak başarımları analizi yapılmıştır. Bu analizin sonucunda gerek sağlık durumu sınıflandırma gerek biyometrik tanıma konularında en yüksek ayırt edicilik sağlayan öznitelik kümeleri ve en yüksek başarımları sağlayan sınıflandırma algoritmaları belirlenmiştir. Yapılan analizlerden elde edilen veriler “Sonuçlar” bölümünde detaylı şekilde açıklanmıştır.


2.8. Biyometrik Tanıma

Bu aşamada, cinsiyet, yaş ve kimlik tanıma olmak üzere üç farklı biyometrik sınıflandırma çalışması yapılmıştır. Bu sayede, sürücü kalp sağlığının takip edilmesi yanında sürücünün kimlik doğrulamasını yapmakta mümkün olabilecektir. Çalışma esnasında, önceki bölümlerde açıklanan öznitelik kümeleri, sınıflandırma sisteminde hem ayrı ayrı hem de beraber kullanılmıştır. Diğer bir deyişle; QRS, TD, WT, PSD ve bütün bu öznitelik kümelerinin kombinasyonu (HEPSİ) olmak üzere 5 farklı öznitelik kümesi kullanılmıştır. Öznitelikler, 2 saniye süre ile kayan pencereler üzerinden hesaplanmıştır. Sınıflandırma performansının başarı ölçütü olarak, hassasiyet ve hatırlama değerlerinin harmonik ortalaması olarak tanımlanan geleneksel F-skoru seçilmiştir. Deneyler esnasında, 3 katlı çapraz onaylama tekniği, adil bir değerlendirme için tercih edilmiştir.


“PhysioBank” fizyolojik sinyal arşivindeki MIT-BIH normal sinüs ritim veri kümesi [75], biyometrik kimlik belirleme deneyleri için kullanılmıştır. Bu veri kümesi, 18 sağlıklı kişinin EKG kayıtlarını içermektedir. Bu kişilerin, belirgin aritmilerinin olmadığı belirtilmiştir. Veri kümesi, 26 ile 45 yaş arasındaki 5 erkek ve 20 ile 50 yaş arasındaki 13 bayan içermektedir. Bu kişilere ait örnek EKG sinyalleri, Şekil 2.8’de gösterilmiştir. Bu veri kümesinin cinsiyet ve yaş dağılımları, Çizelge 2.2’de verilmiştir.




(a)



(b)



(c)



(d)

Şekil 2.8. Veri kümesindeki farklı kişilere ait örnek EKG sinyalleri (a) 32 yaşındaki erkek (b) 20 yaşındaki bayan (c) 26 yaşındaki erkek (d) 28 yaşındaki bayan

Çizelge 2.2. Cinsiyet ve yaş dağılımı

Kişi	Cinsiyet	Yaş
1	erkek	32
2	bayan	20
3	bayan	28
4	bayan	38
5	erkek	42
6	bayan	35
7	erkek	26
8	bayan	32
9	bayan	20
10	bayan	45
11	bayan	32
12	bayan	26
13	bayan	34
14	bayan	41
15	erkek	45
16	erkek	34
17	bayan	38
18	bayan	50

Cinsiyet tanıma problemi için, önceki altbölümde bahsedilen orijinal veri kümesi, kişilerin cinsiyetine göre yeniden düzenlenmiştir. Böylece, her bir sınıfın sırasıyla erkek ve bayan kişilerin EKG kayıtlarına sahip olduğu 2 sınıflı veri kümesi elde edilmiştir. Çizelge 2.3, cinsiyet veri kümesinin özelliklerini listelemektedir.

Çizelge 2.3. Cinsiyet tanıma veri kümesi

Sınıf	Kişi	Çerçeve sayısı
erkek	1, 5, 7, 15, 16	9000
bayan	2, 3, 4, 6, 8, 9, 10, 11, 12, 13, 14, 17, 18	23400

Yaş tanıma için; 30 yaşın altındaki, 30 ile 40 yaş arasındaki ve 40 yaşın üstündeki yaş grupları için 3 sınıflı veri kümesi elde edilecek şekilde kişilerin yaşlarına göre veri kümesi tekrar gruplandırılmıştır. Yaş veri kümesinin ayrıntıları, Çizelge 2.4’de listelenmiştir.

Çizelge 2.4. Yaş tanıma veri kümesi

Sınıf	Kişi	Çerçeve sayısı
< 30	2, 3, 7, 9, 12	9000
30-40	1, 4, 6, 8, 11, 13, 16, 17	14400
> 40	5, 10, 14, 15, 18	9000

Kimlik tanıma için, orijinal 18-sınıflı veri kümesi yeni bir organizasyona tabi tutulmadan doğrudan kullanılmış ve 18 farklı kişi, kendi EKG kayıtlarına dayanılarak tanınmıştır. Çizelge 2.5, bu veri kümesi hakkındaki sayısal bilgiyi özetlemektedir.

Çizelge 2.5. Kimlik tanıma veri kümesi

Sınıf	Kişi	Çerçeve sayısı
id1	1	1800
id2	2	1800
...	...	...
id18	18	1800

2.9. Gerçek-Zamanlı Sistemin Tasarımı ve Gerçekleşmesi

Projenin önceki aşamalarında benzetim ortamında geliştirilen sistem, bu aşamada gerçek-zamanlı sisteme uyarlanmıştır. Gerçek-zamanlı sistemin ana bileşenleri aşağıda listelenmiştir.


- i. Araç simülatörü
- ii. Özel sensör kiti
- iii. Veri toplama kartı
- iv. Bilgisayar
- v. Sinyal işleme yazılımı

Proje kapsamında satın alınan özel sensör kiti araç simülatörünün koltuğuna Şekil 2.9’da görüldüğü gibi konumlandırılmıştır. Bu sayede, sürücünün sırtından EKG sinyalleri ölçülebilmektedir. Bu sensörlerin, konvansiyonel jel tipi EKG elektrotlarından farklı olarak vücuda direkt temas etmesi zorunlu değildir. Özel tasarımı sayesinde çok düşük genlikli EKG sinyallerini yakalayabilme yeteneğine sahiptir. Sürücünün üzerinde aşırı kalın olmamak koşuluyla kıyafetler dahi olsa EKG sinyalleri alınabilmektedir. Dolayısıyla, sürücünün üzerine herhangi bir sensör takılması veya yapıştırılmasına gerek kalmadan, sadece araç koltuğuna oturup sırtını yaslamasıyla EKG sinyalleri toplanabilmektedir.



Şekil 2.9. Özel sensör kitinin araç simülatörü üzerine konumlandırılması


Veri toplama kartı (Şekil 2.10), sensörlerden alınan analog sinyalin önişleme tabi tutulurak sayısal formata dönüştürülmesi ve bilgisayara iletilmesi amacıyla kullanılmaktadır. Önişlemler, sırasıyla, sinyalin bir işlevsel yükselteç (operational amplifier) ile genliğinin yükseltilmesi, çevresel gürültülerin ortadan kaldırılması amacıyla analog bir alçak-geçiren (low-pass) filtre ve şebeke elektriğinden kaynaklanan gürültüleri bastırmak için ise bir çentik (notch) filtre uygulanmasıdır.




Şekil 2.10. Veri toplama kartı

Veri toplama kartı tarafından bilgisayara iletilen sayısal EKG sinyalleri, proje kapsamında geliştirilmiş olan gerçek-zamanlı EKG sinyal işleme yazılımı sayesinde işlenmekte ve sürücü kalp sağlık durumu hakkında bilgilendirmektedir. Yazılım, öncelikle ham halde alınan sayısal EKG sinyalleri üzerinde çeşitli sayısal filtreleme ve güçlendirme


işlemleri uygulamaktadır. Sonraki aşamada ise R noktalarını tespit ederek kalp ritmini ölçmekte ve dakikadaki atım sayısını değerlendirerek “normal”, “bradikardi” veya “taşikardi” şeklinde sınıflandırma yapmaktadır. Bu sayede kullanıcının temel kardiyak probleminin olup olmadığı gözlenebilmektedir. Yazılımın örnek ekran görüntüleri Şekil 2.11-2.13’de verilmiştir.



Şekil 2.11. Gerçek-zamanlı sistem yazılımı arayüzü (Normal Kalp Ritmi)



Şekil 2.12. Gerçek-zamanlı sistem yazılımı arayüzü (Bradikardi)



Şekil 2.13. Gerçek-zamanlı sistem yazılımı arayüzü (Taşikardi)

2.10. Gerçek-Zamanlı Sistemin Eniyilenmesi

Projenin bu aşamasında, gerçek-zamanlı sistemin ürettiği sonuçların daha doğru hale getirilmesi için yazılım çeşitli testlere tabi tutularak tespit edilen hatalar giderilmiş, sinyal güçlendirme ve süzgeçleme işlemlerinin parametreleri optimize edilmiştir.

3. SONUÇLAR

Aşağıda, bu proje kapsamında gerçekleştirilen fizyolojik sinyaller kullanılarak sağlık durumlarının sınıflandırması ve biyometrik tanıma çalışmalarına ilişkin elde edilen sonuçlar sunulmaktadır. Bu çalışmaların devamında, proje raporunun önceki bölümlerinde bahsedilen gerçek zamanlı sistem elde edilmiştir. Bu sistemin başarımı aşağıda sunulan sonuçlar ile örtüşmektedir.

3.1. Fizyolojik sinyaller kullanılarak sağlık durumlarının sınıflandırılması

3.1.1 Farklı kalp sağlık durumlarının otomatik sınıflandırılması

Bu bölümdeki sonuçlar, Physiobank sinyal arşivi [75] kullanılarak normal ritim, konjestif kalp yetmezliği (congestive heart failure), karıncık taşiaritmisi (ventricular tachyarrhythmia) ve atriyal fibrilasyon (atrial fibrillation) isimli 4 farklı kalp sağlık durumunu içeren EKG sinyal veri tabanı üzerinde yapılan çalışmalara aittir.

İlk olarak zaman düzlemi (TD), dalgacık dönüşümü (WT) ve güç spektral yoğunluğu (PSD) temelli öznitelikler çıkartılmıştır. Tüm öznitelikler, 2 saniyelik pencereler veya çerçeveler boyunca hesaplanmış ve her bir sağlık durumu sınıfı için 1200 adet öznitelik vektörü çıkartılmıştır. Daha ayrıntılı bir şekilde ifade edilirse, TD öznitelikler, EKG sinyallerinin belli bir zaman aralığında, enerji, ortalama, standart sapma, maksimum değer, minimum değer, basıklık (kurtosis), yamukluk (skewness) ile maksimum ve minimum değerler arasındaki farklarını içerir. Diğer yandan, WT öznitelikleri ise, EKG sinyallerinin 5-seviye dalgacık paket ayrıştırması ile elde edilen alt-bantların enerjilerini içerir. PSD öznitelikleri ise, EKG sinyallerinin güç spektral yoğunluğundan hesaplanan enerji, ortalama, standart sapma, maksimum değer, minimum değer, basıklık, yamukluk ve yerel fraktal boyut değerlerini içerir. Bu şekilde sırasıyla, her bir çerçeve için 8 adet TD, 32 adet WT ve 11 adet PSD özniteliklerinden oluşan, 3 ayrı öznitelik kümesi elde edilmiştir. Bu noktada, tüm bu özniteliklerin, EKG analizlerinde genellikle kullanılan bir önışlem olan QRS tespitine gerek kalmadan elde edilmiş olmaları vurgulanması gereken bir durumdur. Öznitelik kümesi, bireysel olarak veya kombinasyonlar halinde, iyi bilinen sınıflandırıcılardan olan, Karar Ağacı ve Yapay Sinir Ağları sınıflandırıcılarına uygulanmıştır.

Sınıflandırma performansının başarımlı ölçümü için hem geri getirme (recall) oranı hem de kesinlik (precision) değerlerini dikkate alan geleneksel F-skor tekniği [89] kullanılmıştır.

F1-skor ismi ile de bilinen F-skor, basit bir şekilde, kesinlik ve geri getirme oranı değerlerinin harmonik ortalaması olarak da tanımlanabilir. Tüm öznitelik kümelerinin F-skor sonuçları, Çizelge 3.1.'de listelenmiştir.

Çizelge 3.1. Öznitelik kümelerinin F-skor değerleri

Öznitelik Kümesi	Boyutu	Sınıflandırıcı Tipi	
		Karar Ağacı	Yapay Sinir Ağları
TD	8	0.881	0.822
WT	32	0.887	0.764
PSD	11	0.895	0.839
TD + WT	40	0.932	0.886
TD + PSD	19	0.927	0.904
WT + PSD	43	0.918	0.833
TD + WT + PSD	51	0.947	0.907
SFFS(TD + WT + PSD)	23	0.963	-

Öznitelik kümeleri, işlem süresi açısından karşılaştırıldığında; TD, WT ve PSD yöntemlerinin öznitelik vektörü başına çıkartım süresi, sırasıyla, 2 ms., 105 ms. ve 55 ms.'dir. Bu süreler, Intel Core i7 2.80 GHz işlemcili ve 4 GB RAM içeren bilgisayarlarda ölçülmüştür. İşlem süreleri dikkate alındığında, TD öznitelikler, belirgin bir şekilde makul sınıflandırma performansı ile en üstte yer almaktadır.

Çizelge 3.2. Ardışıl ileri kayan öznitelik seçme yöntemi ile seçilen öznitelikler

Öznitelik No	Öznitelik Tanımı
1	TD (enerji)
2	TD (standart sapma)
3	TD (minimum değer)
4	TD (basıklık)
5	TD (yamukluk)
6	TD (maksimum ve minimum değerler arasındaki fark)
7	WT (alt bant enerjisi #02/32)
8	WT (alt bant enerjisi #03/32)
9	WT (alt bant enerjisi #04/32)
10	WT (alt bant enerjisi #11/32)
11	WT (alt bant enerjisi #12/32)
12	WT (alt bant enerjisi #14/32)
13	WT (alt bant enerjisi #19/32)
14	WT (alt bant enerjisi #20/32)
15	WT (alt bant enerjisi #21/32)
16	WT (alt bant enerjisi #22/32)
17	WT (alt bant enerjisi #24/32)
18	WT (alt bant enerjisi #26/32)
19	WT (alt bant enerjisi #27/32)
20	PSD (minimum değer)
21	PSD (yamukluk)
22	PSD (Bölüm #1/4, yerel fraktal boyut)
23	PSD (Bölüm #3/4, yerel fraktal boyut)

Tüm veri kümesinde, ardışıl ileri kayan öznitelik seçim yönteminin kullanılmasıyla birlikte, öznitelik kümesinin boyutunun %50'den fazla azalmasına ek olarak sınıflandırma başarımları da artmıştır. Ancak işlem süresi özniteliklerin seçiminde temel faktör olarak belirlenirse, TD özniteliklerinin en üst sırada yer aldığı görülmektedir.

3.1.2 Kardiyak aritmilerin otomatik sınıflandırılması

Bu bölümdeki sonuçlar, MIT-BIH aritmi veritabanı [75] üzerinde yapılan çalışmalara aittir. Bu veritabanı içerisindeki 15 farklı kalp atış tipi, ANSI/AAMI EC57:1998 standardı dikkate alınarak beş ana sınıf altında gruplandırılmış ve bu gruplar vasıtasıyla kardiyak aritmilerin otomatik sınıflandırılmasına çalışılmıştır.

Bu çalışmada, altı farklı öznitelik kümesi, C4.5 ve Rastgele Orman olarak bilinen karar ağacı tabanlı iki farklı sınıflandırıcı ile sınıflandırılmıştır. Daha önce bahsedilen öznitelik kümeleri, hem ayrı olarak hem de kombinasyon halinde sınıflandırıcı sisteminde

kullanılmıştır. Özellikle; QRS öznitelikleri, TD öznitelikleri, WT öznitelikleri, PSD öznitelikleri, TD, WT ve PSD özniteliklerinin kombinasyonu (TD+WT+PSD) ve son olarak tüm altı öznitelik kümesinin kombinasyonu (ALL) değerlendirilmiştir. Sınıflandırma performansının başarı ölçütü olarak, hassasiyet ve hatırlama değerlerinin harmonik ortalaması olarak bilinen geleneksel F-skoru [89] seçilmiştir. Deneyler süresince, 3 katlamalı çapraz doğrulama tekniği, adil bir değerlendirme için kullanılmıştır.

Bahsedilen öznitelik kümelerini kullanarak aritmi sınıflandırma sisteminin performansları, Tablolar II ve III de özetlenmiştir. Bu tablolarda en yüksek ağırlıklı ortalama F-skorumları, koyu renkte gösterilmiştir.

TABLO II. C4.5 SINIFLANDIRICISI İÇİN F-SKOR DEĞERLERİ

Sınıf	QRS	TD	WT	PSD	TD+WT+PSD	Hepsi
N	0.976	0.970	0.966	0.963	0.979	0.981
S	0.558	0.588	0.420	0.220	0.593	0.625
V	0.743	0.642	0.622	0.497	0.804	0.811
F	0.516	0.248	0.363	0.313	0.549	0.625
Q	0.942	0.927	0.917	0.929	0.967	0.968
Ağır. Ort.	0.952	0.942	0.933	0.923	0.961	0.964

TABLO III. RASTGELE ORMAN SINIFLANDIRICISI İÇİN F-SKOR DEĞERLERİ

Sınıf	QRS	TD	WT	PSD	TD+WT+PSD	Hepsi
N	0.980	0.974	0.972	0.970	0.982	0.984
S	0.586	0.599	0.332	0.205	0.570	0.594
V	0.790	0.685	0.614	0.563	0.813	0.838
F	0.592	0.261	0.322	0.367	0.444	0.591
Q	0.958	0.940	0.958	0.960	0.984	0.985
Ağır. Ort.	0.960	0.948	0.939	0.933	0.964	0.967

Bu tablolardan görüleceği gibi en yüksek ağırlıklı ortalama F-skoru, bütün öznitelikler (ALL), Rastgele Orman sınıflandırıcısı ile beraber kullanıldığında 0.967 olarak bulunmuştur. Bununla birlikte; TD, WT ve PSD özniteliklerinin kombinasyonu (TD+WT+PSD), çoğu zaman ikinci en yüksek F-skorumu vermiştir. Bu esnada, QRS özniteliklerinin tek başına performansı, TD, WT ve PSD özniteliklerinin kombinasyonunun (TD+WT+PSD) performansına yakındır. Bu sonuçlar, her iki sınıflandırma algoritması için de geçerlidir.

3.2. Fizyolojik sinyaller kullanılarak biyometrik tanıma

Bu bölümdeki sonuçlar, MIT-BIH normal sinüs ritim veri kümesi [75] içerisindeki 18 sağlıklı kişinin ECG kayıtları kullanılarak yapılan biyometrik tanıma çalışmalarına aittir. Biyometrik tanıma problemi cinsiyet, yaş ve kimlik tanınması şeklinde üç ayrı altbaşlıkta incelenmiştir.

3.2.1 Cinsiyet Tanıma

Cinsiyet tanıma problemi için sonuçlar, Tablo III de verilmiş ve buradaki en yüksek F-skoru koyu renkli gösterilmiştir. Bu tablodan görüleceği gibi, en yüksek ağırlıklı ortalama F-skoru, C4.5 karar ağacı sınıflandırıcısında bütün öznitelik kümeleri kullanıldığında 0.986 olarak bulunmuştur. Bunların yanında; QRS, TD ve PSD öznitelikleri ayrı ayrı kullanıldığında, özniteliklerin kombinasyonu C4.5 sınıflandırıcısında kullanıldığında elde edilen performansa benzer bir performans elde edilmiştir.

TABLO 3. C4.5/BAYES AĞ SINIFLANDIRICILAR İÇİN CİNSİYET TANIMA F-SKORLARI

Sınıf	QRS		TD		WT		PSD		HEPSİ	
erkek	0.968	/0.834	0.910	/0.710	0.745	/0.591	0.891	/0.686	0.975	/0.876
bayan	0.988	/0.938	0.966	/0.877	0.904	/0.851	0.959	/0.873	0.990	/0.952
Ağırlıklı Ort.	0.982	/0.909	0.950	/0.831	0.859	/0.779	0.940	/0.821	0.986	/0.931

3.2.2 Yaş Tanıma

Yaş tanıma problemi için sonuçlar, Tablo V de verilmiş ve buradaki en yüksek F-skoru koyu renkli gösterilmiştir. Yaş tanıma problemi için en yüksek ağırlıklı ortalama F-skoru, C4.5 karar ağacı sınıflandırıcısı ile beraber bütün özniteliklerin kombinasyonu kullanıldığında 0.975 olarak elde edilmiştir. Öznitelik kümeleri ayrı ayrı incelendiğinde, QRS ve TD öznitelikleri, en yüksek F-skoruna yakın skorlar vermiştir.

TABLO 5. C4.5/BAYES AĞ SINIFLANDIRICILAR İÇİN YAŞ TANIMA F-SKORLARI

Sınıf	QRS		TD		WT		PSD		HEPSİ	
< 30	0.964	/0.784	0.897	/0.724	0.714	/0.568	0.858	/0.651	0.977	/0.862
30-40	0.974	/0.851	0.907	/0.779	0.757	/0.529	0.890	/0.714	0.977	/0.884
> 40	0.968	/0.819	0.902	/0.764	0.722	/0.550	0.866	/0.660	0.969	/0.818
Ağırlıklı Ort.	0.970	/0.823	0.903	/0.760	0.735	/0.545	0.874	/0.682	0.975	/0.860

3.2.3 Kimlik Tanıma

Kimlik tanıma problemi için sonuçlar, Tablo VII de verilmiş ve yine en yüksek F-skoru koyu renkli gösterilmiştir. Cinsiyet ve yaş tanıma problemlerinin sonuçlarına benzer şekilde, en yüksek ağırlıklı ortalama F-skoru, C4.5 karar ağacı sınıflandırıcısı ile beraber bütün özniteliklerin kullanıldığında 0.972 olarak elde edilmiştir. Bu problemde, öznitelikler ayrı ayrı göz önüne alındığında, sadece QRS öznitelik kümesi, C4.5 sınıflandırıcısı ile beraber kullanıldığında en yüksek F-skoruna yakın skorlar vermiştir.

TABLO 7. C4.5/BAYES AĞ SINIFLANDIRICILAR İÇİN KİMLİK TANIMA F-SKORLARI

Sınıf	QRS		TD		WT		PSD		HEPSİ	
id1	0.990	0.991	0.946	0.876	0.884	0.806	0.993	0.977	0.996	0.990
id2	0.943	0.880	0.890	0.755	0.694	0.620	0.818	0.797	0.972	0.976
id3	0.968	0.964	0.937	0.855	0.566	0.362	0.857	0.798	0.972	0.966
id4	0.989	0.987	0.981	0.969	0.840	0.745	0.962	0.962	0.988	0.990
id5	0.942	0.894	0.883	0.837	0.588	0.524	0.678	0.611	0.959	0.938
id6	0.923	0.870	0.661	0.589	0.426	0.269	0.579	0.477	0.924	0.861
id7	0.966	0.956	0.883	0.832	0.655	0.570	0.974	0.932	0.990	0.989
id8	0.975	0.972	0.975	0.937	0.677	0.494	0.911	0.890	0.979	0.980
id9	0.971	0.937	0.949	0.940	0.671	0.584	0.838	0.803	0.988	0.995
id10	0.952	0.950	0.794	0.689	0.443	0.347	0.861	0.825	0.956	0.929
id11	0.961	0.961	0.903	0.771	0.609	0.501	0.889	0.828	0.981	0.976
id12	0.954	0.945	0.766	0.543	0.432	0.362	0.581	0.439	0.966	0.943
id13	0.921	0.897	0.774	0.671	0.497	0.421	0.745	0.661	0.938	0.905
id14	0.937	0.915	0.881	0.824	0.514	0.476	0.846	0.747	0.958	0.933
id15	0.955	0.941	0.815	0.726	0.529	0.452	0.777	0.673	0.958	0.947
id16	0.979	0.967	0.942	0.913	0.693	0.562	0.929	0.870	0.989	0.962
id17	0.982	0.983	0.853	0.772	0.801	0.730	0.952	0.931	0.989	0.992
id18	0.996	0.989	0.991	0.981	0.877	0.816	0.943	0.945	0.994	0.997
Ağırlıklı Ort.	0.961	0.944	0.879	0.804	0.633	0.536	0.841	0.787	0.972	0.959

4. TARTIŞMA

Sürücülerin rahatsızlıklarını göz ardı ederek uzun süreli yolculuklara çıkması, yolculuk başlangıcında sürücülere engel çıkarmamasına karşın, yolculuğun ilerleyen saatlerinde sürücülerin sürüşlerini ve trafiği etkileyecek biçimde olumsuzluklara sebep olabilmektedir. Bu olumsuzluklar, genellikle, kalp krizi, aritmi, taşikardi, bradikardi, vb. sağlık sorunlarından kaynaklanmaktadır. Uzun süreli sürüşün neden olduğu bu olumsuzluklar, sürücünün refleksini ve performansını önemli ölçüde zayıflatmakta, maddi ve hatta ölüme yol açan kazalara da sebebiyet verebilmektedir. Bu sebepten ötürü, sürücülerin sağlık durumlarını gerçek zamanlı olarak gösteren bir sisteme, kazaların önlenmesi için şiddetle ihtiyaç duyulmaktadır. Bu sistemin, özellikle araçlar için yol güvenliği ile ilgili kaçınılmaz bir unsur haline getirilmesi gerekmektedir.

Bu proje kapsamında, ilk aşamada, sürücülerin araç kullanımlarının benzetim ortamında modellenebilmesi amacıyla bir sürüş simülatörü kurulmuştur. Projenin ikinci aşamasında ise, kalp krizi, aritmi, taşikardi, vb. sağlık sorunu olan kişilerden ve herhangi bir sağlık problemi olmayan kişilerden toplanmış hazır bir EKG sinyal veri tabanı bulunmuştur. Daha sonra, bulunan bu veri tabanındaki sinyallere zaman ve frekans düzlemlerinde analizler yapılmış ve çeşitli öznitelik seçim yaklaşımları kullanılarak ayırt edici öznitelikler çıkartılmıştır. Elde edilen ayırt edici özniteliklerin, en yüksek başarımla sınıflandırılabilmesi için farklı yöntemler denenmiş ve bulunan sonuçlar uluslararası bir konferansta bildiri olarak sunulmuştur. Sunulan bildiride, EKG sınıflandırmada sıkça kullanılan TD, WT ve PSD özniteliklerinin katkıları, sınıflandırılma performansları ve işlem süreleri ayrıntılı bir şekilde incelenmiştir. Her bir öznitelik kümesi bireysel olarak incelendiğinde, PSD öznitelikleri, diğerlerini sınıflandırma performansı açısından geride bırakırken; işlem süresi açısından TD özniteliklerinin daha iyi sonuçlar verdiği görülmektedir. Bununla birlikte, TD, WT ve PSD özniteliklerinin uygun kombinasyonları ile daha iyi sınıflandırma performansına ulaşılmaktadır. Diğer bir ifade ile tüm öznitelik kümeleri, EKG sınıflandırma performansının artırılmasında belirgin bir katkıya sahip olmaktadır. Bu çalışmanın bir diğer ilginç yanı, literatürdeki EKG sınıflandırmalarında oldukça kritik bir ön işlem olarak kabul gören QRS tespiti gerek kalmadan sinyallerin başarılı bir şekilde sınıflandırılmasıdır. Gelecekteki çalışmalarda, daha farklı öznitelik kümeleri ve farklı sınıflandırıcıların kullanılması düşünülmektedir.

Projenin üçüncü aşamasında ise, bir biyometrik kimlik belirleme çalışması yapılmıştır. Biyometrik kimlik belirleme sistemleri, bir kişinin kimliğinin doğrulanmasına gerek duyulduğu veya daha yüksek güvenlik seviyeleri arzu edildiği çeşitli alanlarda potansiyel uygulamalara sahiptir. Bu sistemler, kişilerin fizyolojik ve/veya davranışsal karakteristiklerinden türetilen belirli öznitelikleri kullanarak kişileri tanımlama vasıtasıyla sağlam güvenlik oluştururlar. EKG sinyallerine bağlı biyometrik tanıma sistemleri; yüz, parmak izi ve retina gibi diğer biyometrik verileri kullanan sistemler ile karşılaştırıldığında kısmen yenidir. EKG tabanlı biyometrik kimlik belirleme işlemi, uygun performans sunmakla beraber; bu sistemlerin performanslarını daha da artırmak için yeni özniteliklere veya öznitelik kombinasyonlarına hala ihtiyaç duyulmaktadır. Bu nedenden dolayı, çeşitli özniteliklerin, EKG tabanlı biyometrik kimlik belirleme performansına katkıları bu raporun “Yapılan Çalışmalar” bölümünde ayrıntılı bir şekilde incelenmiştir. Biyometrik kimlik belirleme problemi, cinsiyet, yaş ve kimlik belirlemeyi içeren 3 temel tanıma problemi olarak ele alınmıştır. Bu çalışmada göz önüne alınan her bir tanıma problemi için en yüksek F-skoru, bütün öznitelik kümeleri beraber kullanıldığında elde edilmiştir. Bunun yanında, bütün tanıma problemlerinde, sadece QRS tabanlı öznitelikler, tüm özniteliklerin kombinasyonunun gösterdiği performansa çok yakın bir performans sergilemiştir. Bu bulgular, kullanılan her iki sınıflandırıcı algoritması için de geçerlidir. Aynı zamanda TD öznitelikleri, özellikle cinsiyet ve yaş tanıma için başarılı sınıflandırma performansı vermiştir. Bu ifade, C4.5 sınıflandırıcısı için geçerlidir.

Projenin dördüncü aşamasında ise, oldukça sık karşılaşılan kardiyak bir rahatsızlık türü olan aritmi sınıflandırma üzerine çalışmalar yapılmıştır. Aritmi, bütün dünyadaki insanlar arasında kardiyak anormallik olarak yaygın bir şekilde görülmesinden dolayı birçok araştırmacı, aritmi sınıflandırma problemi ile ilgilenmektedir. Bu çalışma, MIT-BIH aritmi veritabanı kullanılarak gerçekleştirilmiştir. Özniteliklerin hepsi, MIT-BIH veritabanında bulunan EKG sinyalleri üzerinden elde edilmiştir. Öznitelik kümelerinin çeşitliliği göz önüne alındığında, yaygın olarak kullanılan özniteliklerin ve onların kombinasyonlarının aritmi sınıflandırma performansına katkıları, bu çalışmada kapsamlı bir şekilde irdelenmiştir. Deneyler, özniteliklerin ayrı ayrı kullanılması yerine kombinasyonlarının kullanılmasının her iki sınıflandırıcı için daha iyi F-skorları verdiğini göstermiştir. Bu sonucun altında yatan neden, her bir öznitelik kümesinin EKG sinyalleri hakkında farklı, fakat kısmen ayırt edici bilgileri içermesidir. Hâlbuki özniteliklerin kombinasyonu, her bir öznitelik kümesinin bütün kuvvetli yanlarına sahiptir. Ayrıca bütün deneyler, ağırlıklı ortalama F-skorlarına göre

Rastgele Orman (Random Forest) ağaç sınıflandırıcısının, C4.5 sınıflandırıcıdan biraz daha üstün olduğunu belirgin bir şekilde göstermektedir.

Projenin son aşamasında ise, tüm proje bulgularından yola çıkılarak gerçek-zamanlı bir sistem tasarımı ve gerçekleştirilmesi planlanmıştır. Ancak, proje sürecinde alınmış olan “Algılayıcı Kiti” sayesinde böyle bir sistemin tasarlanmasına ihtiyaç duyulmamıştır. Bu kitten faydalanılarak sürücü koltuklarına yerleştirilen temassız (non-intrusive) algılayıcılar sayesinde araç simülatörü içerisindeki direksiyon, vites ve pedal sistemiyle yürütülen sürüşler esnasında elde edilen fizyolojik sinyallerin içeriğine bakılarak kişinin temel bir kardiyak aritmi problemini (taşikardi veya bradikardi) yaşayıp yaşamadığı açık ve net bir biçimde tespit edilmiştir. Bu sonuç, bilgisayar ortamında tasarlanan kullanıcı arabirimi ile kişiye gerçek-zamanlı bir biçimde gösterilmiştir. Temel kardiyak aritmi probleminin tespiti esnasında karşılaşılan sorunlar, iki ana başlıkta toplanabilir. Bu başlıklardan ilki, araç simülatöründe sürüş denemeleri esnasında aracı kullanan kişinin kıyafetinin türüdür. Tasarlanan sistem, özellikle pamuk veya pamuk karışımı kıyafetlerde başarılı sonuçlar sağlarken; özellikle polyester, naylon, vb. karışımı giysilerde etkili sinyal görüntülemeye olanak tanımamaktadır. Bu durumun sebebi, farklı türden malzemelerin elektrik iletkenliğinin farklı oluşudur. Pamuklu giysiler elektriği iyi iletmesine karşın; polyester, naylon, vb. karışımı giysiler elektriği iyi iletmemektedir. İkinci karşılaşılan sorun başlığı ise, araç simülatöründe sürüş esnasında kişinin ani hareketler yapması sonucu anlık ve geçici sinyal iletim sorunlarının yaşanmasıdır. Bu husus üzerinde çalışmalarımız sürmekte olup; daha az sinyal kesintisi sağlayacak şekilde sürücü koltuklarına gürbüz sensör implantasyonu üzerinde çalışılmaktadır. Sonuç olarak, üzerinde çalışılan bu bilimsel araştırma projesi tamamlanmış olup; bilimsel araştırma projesinden yayın üretilmesi aşamasına geçilmiştir.

5. KAYNAKLAR

- [1] T. Wartzek, B. Eilebrecht, J. Lem, H.-J. Lindner, S. Leonhardt, "ECG on the Road: Robust and Unobtrusive Estimation of Heart Rate", *IEEE Transactions On Biomedical Engineering*, Vol. 58, No.11, pp. 3112-3120, 2011.
- [2] I. Gulera, E. D. Ubeyli, "ECG beat classifier designed by combined Neural network model", *Pattern Recognition*, Vol. 38, No. 2, pp. 199–208, 2005.
- [3] E. D. Übeyli, "Usage of eigenvector methods in implementation of automated diagnostic systems for ECG beats", *Digital Signal Processing*, Vol. 18, No.1, pp. 33–48, 2008.
- [4] V.S. Murthy, S. Ramamoorthy, N. Srinivasan, S. Rajagopal, M.M. Rao, "Analysis of photoplethysmographic signals of cardiovascular patients," in *Proc. 23rd IEEE Annual International Conference EMBS*, Oct. 2001, pp. 2204 – 2207.
- [5] R. N. Khushaba, S. Kodagoda, S. Lal, and G. Dissanayake, "Driver Drowsiness Classification Using Fuzzy Wavelet-Packet-Based Feature Extraction Algorithm", *IEEE Transactions On Biomedical Engineering*, Vol. 58, No. 1, January 2011.
- [6] M. Patel, S.K.L. Lal, D. Kavanagh and P. Rossiter, "Applying neural network analysis on heart rate variability data to assess driver fatigue", *Expert Systems with Applications*, Vol. 38, pp. 7235-7242, 2011.
- [7] L. Shiwu, W. Linhong, Y. Zhifa, J. Bingkui, Q. Feiyan and Y. Zhongkai, "An active driver fatigue identification technique using multiple physiological features", *Int. conf. on Mechatronic Science, Electric Engineering and Computer*, pp. 733-737, China 2011.
- [8] J. Vicente, P. Laguna, A. Bartra and R. Bailon, "Detection of driver's drowsiness by means of HRV analysis", *Computing in Cardiology*, Vol. 38, pp. 89-92, 2011.
- [9] Z. Hongjun, "The research of ECG diagnosis system based on support vector machines", *Journal of Convergence Information Technology*, Vol. 6, No. 3, pp. 35-44, March 2011.
- [10] D. Giakoumis, D. Tzovaras, K. Moustakas and G. Hassapis, "Automatic recognition of boredom in video games using novel biosignal moment-based features", *IEEE Transactions on Affective Computing*, Vol. 2, No. 3, pp. 119-133, 2011.
- [11] D. C. Randall and Y. M. El-Wazir, *ECG Interpretation*: Hayes Barton Press, 2004.
- [12] P. de Chazal and R. B. Reilly, "A comparison of the ECG classification performance of different feature sets," in *Proc. Computers in Cardiology*, vol. 27, 2000, pp. 327–330.
- [13] M. Llamado Soria and J. P. Martinez, "An ECG classification model based on multilead wavelet transform features," in *Proc. Computers in Cardiology*, vol. 34, 2007, pp. 105–108.
- [14] A. Daamouche, L. Hamami, N. Alajlan, and F. Melgani, "A wavelet optimization approach for ECG signal classification," *Biomedical Signal Processing and Control*, vol. 7, pp. 342–349, 2012.
- [15] P. Y. Muller, N. Contento, and H. Rix, "Fractal dimension on ECG," in *Proc. Engineering in Medicine and Biology Society, 14th Annual International Conference of the IEEE*, 1992, pp. 977–978.
- [16] A. N. Esgiar and P. K. Chakravorty, "Electrocardiogram signal classification based on fractal features," in *Proc. Computers in Cardiology*, 2004, pp. 661–664.
- [17] E. D. Ubeyli, "Statistics over features of ECG signals," *Expert Systems with Applications*, vol. 36, pp. 8758–8767, 2009.
- [18] Martis R. J., Acarya U. R. and Min L. C., *ECG Beat Classification Using PCA, LDA, ICA and Discrete Wavelet Transform*, *Biomedical Signal Processing and Control*, 2013; 8: 437-448.
- [19] Akira Kurita, MD, Bonpei Takase, MD, Toshiaki Ishizuka*, MD *Disaster and Cardiac Disease, Ana Kar Der* 2001;1:101-106.

- [20] Martis R. J., Acarya U. R., Mandana K. M, Ray A. K. and Chakraborty C., Application of Principal Component Analysis to ECG Signals for Automated Diagnosis of Cardiac Health, *Expert Systems with Application* 2012; 39: 11792-11800.
- [21] Samuel Levy, Atrial Fibrillation, the Arrhythmia of the Elderly, Causes And Associated Conditions, *Ana Kar Der* 2002; 2: 55-60.
- [22] Haseena H. H., Mathew A. T. and Paul J. K., Fuzzy Clustered Probabilistic and Multi Layered Feed Forward Neural Networks for Electrocardiogram Arrhythmia Classification, *Journal of Medical Systems* 2011; 35: 179-188.
- [23] Erdoğan O., Holter monitoring in the prognosis of sudden cardiac death, *Anatol J Cardiol* 2007; 7 Suppl 1: 64-7.
- [24] S. Junnila, A. Akhbardeh, L. C. Barna, I. Defee, A. Värri, "A Wireless Ballistocardiographic Chair", *Proc. of the 28th Annual Int. Conf. of the Engineering in Medicine and Biology Society*, pp. 5932-5935, 2006, New York City, USA.
- [25] O. A. Postolache, P. M. B. Silva Girao, J. Mendes, E. C. Pinheiro, G. Postolache, "Physiological Parameters Measurement Based on Wheelchair Embedded Sensors and Advanced Signal Processing", *IEEE Transactions on Instrumentation and Measurement*, Vol. 59, No. 10, pp. 2564-2574, 2010.
- [26] A. Akhbardeh, "Signal Classification using Novel Pattern Recognition Methods and Wavelet Transforms", Thesis for the degree of Doctor of Technology, Tampere University of Technology, Tampere, Finland, 2007.
- [27] R. R. Singh, S. Conjeti and R. Banerjee, "An Approach for Real Time Stress-Trend Detection in Physiological Signals in Wearable Computing Systems for Automotive Drivers", *Proc. 14th International IEEE Annual Conf. on Intelligent Transportation Systems*, pp. 1477-1482, October 2011, Washington DC, USA.
- [28] H. B. Lee, J. S. Kim, Y. S. Kim, H. J. Baekl, M. S. Ryu and K. S. Park, "The relationship between HRV parameters and stressful driving situation in the real road", *Proc. 6th International Special Topic Conference on Information Technology Applications in Biomedicine (ITAB 2007)*, pp. 198-200, 2007.
- [29] B.-G. Lee S.-J. Jung W.-Y. Chung, "Real-time physiological and vision monitoring of vehicle driver for non-intrusive drowsiness detection", *Communications, IET*, Vol. 5, No. 17, pp. 2461 - 2469, 2011.
- [30] H.-S. Shin, S.-J. Jung, J.-J. Kim and W.-Y. Chung, "Real Time Car Driver's Condition Monitoring System", *IEEE conference on Sensors*, pp.951-954, 2010.
- [31] R. R. Singh and R. Banerjee, "Multi-parametric Analysis of Sensory Data collected from Automotive Drivers for Building a Safety-Critical Wearable Computing System," *Proc. 2nd Int. Conf. on Computer Engineering and Technology (ICCET 2010)*, pp. V1-355 - V1-360, Chengdu, China, April 2010.
- [32] A. Rovetta, C. Zocchi, A. Giusti, A. Adami, F. Scaramellini, "Feasibility Analysis on A Car Control System by Psychic-Physical Parameters", *International Journal of Mechanics and Control*, Vol. 2, No. 7, pp. 31-39, 2006.
- [33] S. Raghav, and A. K. Mishra "Fractal Feature Based ECG Arrhythmia Classification", *Proceedings of IEEE TENCON* 2008.
- [34] C.-H. Lin, C.-L. Kuo *, J.-L. Chen, and W.-D. Chang, "Fractal Features for Cardiac Arrhythmias Recognition Using Neural Network Based Classifier", *Proceedings of the 2009 IEEE International Conference on Networking, Sensing and Control*, March 26-29, 2009, Japan.
- [35] A.K. Mishra, S. Raghav, "Local fractal dimension based ECG arrhythmia classification", *Biomedical Signal Processing and Control*, Vol. 5, pp. 114-123, 2010.

- [36] K. T. Lai and K. L. Chant , “Real-time Classification of Electrocardiogram based on Fractal and Correlation Analyses”, Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vol. 20, No. 1,1998.
- [37] K. Murata, E. Fujita, S. Kojima, S. Maeda, Y. Ogura, T. Kamei, T. Tsuji, S. Kaneko, M. Yoshizumi, N. Suzuki, “Noninvasive Biological Sensor System for Detection of Drunk Driving”, IEEE Transactions on Information Technology In Biomedicine, Vol. 15, No. 1, pp. 19-25, 2011.
- [38] De Chazal P. and Reilly R.B., A patient-adapting heartbeat classifier using ECG morphology and heartbeat interval features, IEEE Transactions on Biomedical Engineering 2006; 53: no. 12, 2535–2543.
- [39] Ince T., Kiranyaz S. and Gabbouj M., A generic and robust system for automated patient-specific classification of ECG signals, IEEE Transactions on Biomedical Engineering 2009; 56: no. 5, 1415–1426.
- [40] Inan O.T., Giovangrandi L. and Kovacs G.T.A.,Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing interval features, IEEE Transactions on Biomedical Engineering 2006; 53: no.12, pp. 2507–2515.
- [41] Gunal S., Ergin S., Sora Gunal E., and Uysal A. K., ECG classification using ensemble of features, in Proc. IEEE 47th Annual Conference on Information Sciences and Systems, 2013, Baltimore, MD, P. 1-5.
- [42] Hu Y. H., Palreddy S. and Tompkins W.J., A patient-adaptable ECG beat classifier using a mixture of experts approach, IEEE Transactions on Biomedical Engineering 1997; 44: no. 9, 891–900.
- [43] Llamedo M. and Martinez J. P., An automatic patient adapted ECG heartbeat classifier allowing expert assistance, IEEE Transactions on Biomedical Engineering 2012; 59: no.8, 2312–2320.
- [44] Jiang W. and Kong G. S., Block-based neural networks for personalized ECG signal classification, IEEE Transactions on Neural Networks 2007; 18: no. 6, 1750-1761.
- [45] S. M. Jadhav, S. L. Nalbalwar, A. A. Ghatol, “Modular Neural Network Based Arrhythmia Classification System Using ECG Signal Data”, International Journal of Information Technology and Knowledge Management, Vol. 4, No. 1, pp. 205-209, 2011.
- [46] Wang J.-S., Chiang W.-C., Hsu Y.-L. and Yang Y.-T. C., ECG Arrhythmia Classification Using a Probabilistic Neural Network with a Feature Reduction Method, Neurocomputing 2013; 116: 8-45.
- [47] C. K. Chen, C. L.Lin, and Y. M. Chiu, “Individual identification based on chaotic electrocardiogram signals,” In Industrial Electronics and Applications (ICIEA), 2011 6th IEEE Conference on (pp. 1771-1776), June 2011.
- [48] Y. Gahi, M. Lamrani, A. Zoglat, M. Guennoun, B. Kapralos, and K. El-Khatib, “Biometric identification system based on electrocardiogram data,” In New Technologies, Mobility and Security, 2008. NTMS'08. (pp. 1-5). IEEE, November 2008.
- [49] J. Lee, C. Youngjoon, and K. Inyoung, "Personal identification based on vectorcardiogram derived from limb leads electrocardiogram," Journal of Applied Mathematics 2012.
- [50] P. Sasikala and R. S. D. Wahidauanu, “Identification of Individuals using Electrocardiogram,” IJCSNS International Journal of Computer Science and Network Security, 10(12), pp.147-153, 2010.
- [51] A. D. Chan, M. M.Hamdy, A. Badre and V. Badee, “Wavelet distance measure for person identification using electrocardiograms, “ IEEE Transactions on Instrumentation and Measurement, 57(2), 248-253, 2008.
- [52] M. M. Tawfik and H. S. T. Kamal, "Human identification using QT signal and QRS complex of the ECG," The Online Journal on Electronics and Electrical Engineering (OJEEE) vol3, 2011.

- [53] F. Wang, D. Agrafioti, D. Hatzinakos, and K. N. Plataniotis, "Analysis of human electrocardiogram for biometric recognition," *EURASIP journal on Advances in Signal Processing*, vol. 2008, no. 19, pp. 19:1–19:11, 2008.
- [54] S.A. Israel, J.M. Irvine, A. Cheng, M.D. Wiederhold and B. K. Wiederhold, "ECG to identify individuals," *Pattern Recognition*, 38(1), pp. 133–142, 2005.
- [55] S.-C. Fang and H.-L. Chan, "Human identification by quantifying similarity and dissimilarity in electrocardiogram phase space," *Pattern Recognition*, vol. 42, pp. 1824–1831, Sep. 2009.
- [56] G. Wubbeler, M. Stavridis, D. Kreiseler, R.-D. Bousseljot, and C. Elster, "Verification of humans using the electrocardiogram," *Pattern Recognition Letters*, vol. 28, pp. 1172–1175, 2007.
- [57] K. Sidek and I. Khalil, "Automobile Driver Recognition Under Different Physiological Conditions Using the Electrocardiogram," In *Computing in Cardiology*, vol. 38, pp.753-756, 2011.
- [58] K. S. Kim, T. H. Yoon, J. W. Lee, D. J. Kim, and H. S. Koo, "A robust human identification by normalized time-domain features of electrocardiogram," In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. IEEE 27th Annual International Conference of the* (pp. 1114-1117).
- [59] T. W. Shen, W. J. Tompkins, and Y. H. Hu, "One-lead ECG for identity verification," in *Proceedings of the 2nd Joint Engineering in Medicine and Biology, 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society (EMBS/BMES '02)*, vol. 1, pp. 62–63, Houston, Tex, USA, October 2002.
- [60] T. W. Shen, "Biometric identity verification based on electrocardiogram (ECG)," Ph.D. dissertation, University of Wisconsin, Madison, Wis, USA, 2005.
- [61] S. Zokaei, K. Faez, "Human Identification Based on Electrocardiogram and Palmprint", *International Journal of Electrical and Computer Engineering (IJECE)*, 2(2), pp.261-266, 2012.
- [62] C. Ye, M. T. Coimbra and B. V. Kumar, "Investigation of human identification using two-lead electrocardiogram (ECG) signals," In *Biometrics: Theory Applications and Systems (BTAS), 2010 Fourth IEEE International Conference on* , pp. 1-8, September 2010.
- [63] A. D. Chan, M. M. Hamdy, A. Badre and V. Badee, "Person identification using electrocardiograms," In *Electrical and Computer Engineering, CCECE'06, Canadian Conference on* , pp. 1-4, 2006.
- [64] S. Saechia, J. Koseeyaporn and P. Wardkein, "Human identification system based ECG signal," In *TENCON 2005, 2005 IEEE Region 10*, pp. 1-4, 2005.
- [65] M. Li and S. Narayanan, "Robust ECG biometrics by fusing temporal and cepstral information," in *Proc. 2010 20th Int. Conf. Pattern Recognition (ICPR)*, pp. 1326–1329, Aug. 2010.
- [66] J. Wang, M. She, S. Nahavandi and A. Kouzani, "Human Identification From ECG Signals Via Sparse Representation of Local Segments," *Signal Processing Letters, IEEE*, 20(10), pp.937-940, 2013.
- [67] A. Kaul, A. S. Arora and S. Chauhan, "ECG based human authentication using synthetic ECG template," In *Signal Processing, Computing and Control (ISPCC), 2012 IEEE International Conference on*, pp. 1-4, March 2012.
- [68] H. Silva, A. Lourenço, F. Canento, A. Fred, "ECG Biometrics: Principles and Applications," In: *6th Int. Conf. on Bio-inspired Systems and Signal Processing*, pp. 228–235, 2013.
- [69] S. Kouchaki, A. Dehghani, S. Omranian, R. Boostani, "ECG-Based Personal Identification Using Empirical Mode Decomposition and Hilbert Transform," *IEEE 16th Symposium on Artificial Intelligence & Signal Processing (AISP 2012)*, May 2-3, 2012.
- [70] N. Venkatesh and S. Jayaraman, "Human electrocardiogram for biometrics using DTW and FLDA," in *Proc. 2010 20th Int. Conf. Pattern Recognition (ICPR)*, pp.3838–3841, Aug. 2010.

- [71] J. M. Irvine and S. A. Israel, "A sequential procedure for individual identity verification using ECG," *EURASIP Journal on Advances in Signal Processing*, vol. 2009, no. 3, pp. 3:1–3:13, 2009.
- [72] D. P. Coutinho, A. LN Fred, and M. AT Figueiredo. "One-lead ECG-based personal identification using Ziv-Merhav cross parsing," *Pattern Recognition (ICPR)*, 20th International Conference on. IEEE, 2010.
- [73] F. Sufi and K. Ibrahim, "Faster person identification using compressed ECG in time critical wireless telecardiology applications," *Journal of Network and Computer Applications* 34(1), pp.282-293, 2011.
- [74] I. Odinaka, P. Lai; A. D. Kaplan, J. A. O'Sullivan, E. J. Sirevaag, and J. W. Rohrbaugh, "ECG Biometric Recognition: A Comparative Analysis," *Information Forensics and Security, IEEE Transactions on*, vol.7, no.6, pp.1812-1824, Dec. 2012.
- [75] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, and H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, 2000.
- [76] Valentin, J.-P. (2010). Reducing QT liability and proarrhythmic risk in drug discovery and development. *British journal of pharmacology*, 159, 5-11.
- [77] L. Biel, O. Pettersson, L. Philipson, and P. Wide, "ECG analysis: A new approach in human identification," *IEEE Transactions on Instrumentation and Measurement*, 50(3), pp. 808–812, Jun. 2001.
- [78] M. Stamp and P. Stavroulakis, *Handbook of Information and Communication Security* (German. In: Springer, Link) p451–478, 2010.
- [79] Mallat S., *A Wavelet Tour of Signal Processing*: Academic Press; 2001
- [80] Coifman R. R. and Wickerhauser M. V., Entropy-based algorithms for best basis selection, *IEEE Transactions on Information Theory* 1992; 38:713–718.
- [81] B. B. Mandelbrot, *The Fractal Geometry of Nature*, 1983.
- [82] S. Spasic, "Spectral and fractal analysis of biosignals and coloured noise," in *Proc. 5th International Symposium on Intelligent Systems and Informatics*, 2007, pp. 147–149.
- [83] Whitney, A.W., 1971, A direct method of nonparametric measurement selection, *IEEE Transactions on Computers*, 20, 1100–1103.
- [84] Marill, T. and Green, D. M., 1963, On the effectiveness of receptors in recognition system, *IEEE Transactions on Information Theory*, 9, 11–17.
- [85] Stearns, S. D., 1976, On selecting features for pattern classifiers, *3rd International Conference on Pattern Recognition*, Coronado, CA, 71-75.
- [86] Pudil, P., Novovicova, J. and Kittler, J., 1994, Floating search methods in feature selection, *Pattern Recognition Letters*, 15, 1119–1125.
- [87] S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, fourth ed., Academic Press, 2008.
- [88] L. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice-Hall, Inc., 1994.
- [89] C. D. Manning, P. Raghavan, and H. Schutze, *Introduction to Information Retrieval*: Cambridge University Press, New York, USA, 2008.

6. EK-I

PROJE DESTEĞİ	: 94.658,00 TL
HARCANAN MİKTAR	: 74.299,32 TL
EK DESTEK	: —

PROJE KAPSAMINDA ALINAN CİHAZ VE DEMİRBAŞLAR:			
No	Adı	Markası	Yeri
1	2 Adet Sürücü Koltuğu (Araç Simülatörü)	Seatbox	ESOGU Ele. – Elo. Müh.
2	2 Adet Direksiyon, Vites ve Pedal Sistemi (Araç Simülatörü)	Logitech	ESOGU Ele. – Elo. Müh.
3	2 Adet Ayaklı 3D LED TV ve 3D gözlük seti (Araç Simülatörü)	LG	ESOGU Ele. – Elo. Müh.
4	1 Adet Taşınabilir EKG ölçüm cihazı	Labtech	ESOGU Ele. – Elo. Müh.
5	1 Adet Elektromekanik Film (EMFI) ve sensör (algılayıcı) seti	EMFIT	ESOGU Ele. – Elo. Müh.
6	2 Adet kişisel bilgisayar (PC)	OEM	ESOGU Ele. – Elo. Müh.
7	2 Adet Dizüstü bilgisayar	HP	ESOGU Ele. – Elo. Müh.
8	1 Adet Ofis Yazıcısı	HP	ESOGU Ele. – Elo. Müh.
9	1 Adet Tarayıcı	Canon	ESOGU Ele. – Elo. Müh.
10	5 Adet Harici sabit disk	Samsung	ESOGU Ele. – Elo. Müh.
11	1 Adet projeksiyon cihazı	BENQ	ESOGU Ele. – Elo. Müh.
12	2 Adet sunum cihazı (data presenter)	Logitech	ESOGU Ele. – Elo. Müh.
13	5 Adet 16 GB USB flash bellek	Corsair	ESOGU Ele. – Elo. Müh.
14	3 Adet ofis masası, 3 Adet kollu çalışma koltuğu, 2 Adet ofis sandalyesi, 1 Adet sehpa, 1 Adet ayaklı beyaz tahta	Hedef	ESOGU Ele. – Elo. Müh.
15	Algılayıcı Kiti	Plessey Semiconductors	ESOGU Ele. – Elo. Müh.

7. EK-II